



# VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

BRNO UNIVERSITY OF TECHNOLOGY

## FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH TECHNOLOGIÍ

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

## ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ

DEPARTMENT OF BIOMEDICAL ENGINEERING

## HODNOCENÍ KVALITY SPÁNKU

SLEEP QUALITY ASSESSMENT

### BAKALÁŘSKÁ PRÁCE

BACHELOR'S THESIS

### AUTOR PRÁCE

AUTHOR

Petr Benáček

### VEDOUCÍ PRÁCE

SUPERVISOR

Ing. Marina Ronzhina, Ph.D.

BRNO 2020

# Bakalářská práce

bakalářský studijní obor **Biomedicínská technika a bioinformatika**

Ústav biomedicínského inženýrství

**Student:** Petr Benáček

**ID:** 203654

**Ročník:** 3

**Akademický rok:** 2019/20

**NÁZEV TÉMATU:**

## Hodnocení kvality spánku

### POKYNY PRO VYPRACOVÁNÍ:

1) Proveďte literární rešerši v oblasti počítačového zpracování a analýzy biologických signálů naměřených ve spánku. Zaměřte se na metody používané pro detekci spánku a metriky pro hodnocení kvality spánku. 2) Seznamte se s databází spánkových signálů dostupnou na ÚBMI a navrhnete postup pro analýzu signálů z této databáze. Výstupem vámi navrženého postupu by měl být odhad kvality spánku měřených osob. 3) Realizujte vybrané metody analýzy spánkových dat v prostředí MATLAB. 4) Statisticky vyhodnoťte účinnost navržených metod či jejich kombinací. 5) Dosažené výsledky vhodně interpretujte a porovnejte s dostupnými údaji z literatury. 6) Diskutujte výhody a limitace použitých metod a možnosti jejich vylepšení.

### DOPORUČENÁ LITERATURA:

[1] SPRIGGS, William. Essentials of polysomnography. A training guide and reference for sleep technicians. Jones and Bartlett Publishers, 2009, 615 s. ISBN 978-0-7637-8106-4.

[2] MOSER, Doris et al. Sleep classification according to AASM and Rechtschaffen & Kales: Effects on Sleep Scoring Parameters. Sleep. 2009, č. 32, s. 139-149. ISSN 1550-9109.

[3] SANEI, Saeid a Jonathon CHAMBERS. EEG signal processing. Wiley, 2007, 312 s. ISBN 978-0-470-02581-9.

**Termín zadání:** 3.2.2020

**Termín odevzdání:** 5.6.2020

**Vedoucí práce:** Ing. Marina Ronzhina, Ph.D.

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda oborové rady

### UPOZORNĚNÍ:

Autor bakalářské práce nesmí při vytváření bakalářské práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

## **Abstrakt**

Tato bakalářská práce se zabývá automatickým hodnocením kvality spánku pomocí neuronových sítí. Pro hodnocení jsou využívána data o pohybu a tepové frekvenci naměřená pomocí chytrých hodinek Apple Watch. Z těchto dat byly vypočteny statistické veličiny, které byly následně využity jako vstup do navržených neuronových sítí. Jejich cílem bylo automaticky rozpoznat spánek a bdění. V tomto případě byla sensitivita 89 % a specificita 70 %, což jsou srovnatelné hodnoty s jinými studiemi. Dále byla data rozdělena také do kategorií W (bdění), NON REM a REM. Z výstupu vytvořených neuronových sítí byly odvozeny parametry hodnotící kvalitu spánku, jako například TST, % REM nebo sleep latency.

## **Klíčová slova**

Spánek, hodnocení kvality spánku, klasifikace, chytré hodinky, neuronová síť

## **Abstract**

The topic of this bachelor thesis is an automatic sleep quality assessment using artificial neural network. To assess the quality of sleep were used the movement and heart rate data measured by Apple Watch smartwatch. From these data, statistical variables were calculated. Then were they used as an input to the neural networks. The goal was to automatically identify sleep and wakefulness. In this case, the sensitivity was 89 % and the specificity was 70 %. These values are comparable with other studies. Furthermore, the data were also divided into categories W (wakefulness), NON REM and REM. Parameters evaluating sleep quality, such as TST, % REM or sleep latency, were derived from the output of the neural networks created.

## **Keywords**

Sleep, sleep assessment, classification, smartwatch, neural network

## **Bibliografická citace**

BENÁČEK, Petr. *Hodnocení kvality spánku*. Brno, 2020. Dostupné také z: <https://www.vutbr.cz/studenti/zav-prace/detail/126691>. Bakalářská práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce Marina Ronzhina.

## **Prohlášení**

*„Prohlašuji, že svou bakalářskou práci na téma Hodnocení kvality spánku jsem vypracoval samostatně pod vedením vedoucí bakalářské práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.*

*Jako autor uvedené bakalářské práce dále prohlašuji, že v souvislosti s vytvořením této bakalářské práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.*

V Brně dne:

.....

podpis autora

## **Poděkování**

*Mé poděkování patří Ing. Marině Ronzhině, Ph.D. za odborné vedení, trpělivost a ochotu, kterou mi v průběhu zpracování bakalářské práce věnovala.*

V Brně dne:

.....  
podpis autora

# Obsah

Úvod .....	12
1. Fyziologie spánku.....	13
1.1 Biologický rytmus .....	13
1.2 Fáze spánku .....	13
1.3 Spánkový cyklus.....	14
1.4 Poruchy spánku .....	15
2. Standartní metody monitorování spánku.....	17
2.1 Dotazníky a škály .....	17
2.2 Spánkové deníky .....	17
2.3 Aktigrafie.....	17
2.4 Polysomnografie (PSG).....	19
3. hodnocení spánkových dat .....	21
3.1 Manuální hodnocení spánkových dat.....	21
3.2 Automatické hodnocení spánkových dat.....	22
4. Zpracovávaná data.....	27
4.1 Protokol měření .....	27
4.2 Popis naměřených dat.....	28
4.3 Předzpracování dat .....	29
4.4 Výpočet parametrů ze získaných signálů .....	31
4.5 Standardizace parametrů .....	33
4.6 Statistická analýza parametrů.....	33
5. Klasifikace spánku .....	36
5.1 Klasifikace fází W a S pomocí neuronové sítě.....	36
5.1.1 Realizace neuronové sítě .....	36
5.1.2 Výsledky klasifikace pomocí neuronové sítě za využití všech parametrů .....	38
5.1.3 Klasifikace W a S neuronovou sítí pouze z dat o tepové frekvenci .....	41
5.1.4 Klasifikace W a S neuronovou sítí pouze z dat akcelerometru .....	43
5.1.5 Porovnání dosažených výsledků při klasifikaci W a S.....	44
5.2 Klasifikace W, NREM a REM pomocí neuronových sítí .....	44
5.3 Porovnání dosažených výsledků s literaturou .....	47
6. Výpočet parametrů hodnotících kvalitu spánku.....	49
Závěr.....	55

## Seznam zkratek

### Zkratky:

AASM	...	Americká akademie spánkové medicíny
EEG	...	Elektroencefalografie
EKG	...	Elektrokardiografie
EMG	...	Elektromyografie
EOG	...	Elektrookulografie
MSE	...	Střední kvadratická odchylka
PPG	...	Photoplethysmogram
PSG	...	Polysomnografie
REM	...	Rychlé pohyby očí (Rapid eye movement)
SE	...	Efektivita spánku (Sleep efficiency)
SCN	...	Suprachiasmatické centrum
SMA	...	Signal magnitude area
SMV	...	Signal vector magnitude
SVM	...	Support vector machines
TRT	...	Celkový čas záznamu
TST	...	Celkový čas spánku
TWT	...	Celkový čas vzhůru (Total wake time)
WASO	...	Probuzení po počátku spánku



## Seznam obrázků

Obr. 1-1 Příklad hypnogramu [6] .....	15
Obr. 2-1 Vzor spánkového deníku FN Brno [7].....	17
Obr. 2-2 Příklad nasnímaných dat pomocí aktigrafu [10].....	18
Obr. 2-3 Příklad biosignálů naměřených během PSG vyšetření [12] .....	19
Obr. 3-1 Příklady obvyklých aktivačních funkcí .....	22
Obr. 3-2 Příklad topologie neuronové sítě .....	23
Obr. 3-3 Příklady různě zvolených velikostí $\mu$ .....	24
Obr. 3-4 Model jednoduchého rozhodovacího stromu.....	25
Obr. 3-5 Kernel trick příklad [17] .....	26
Obr. 4-1 Data získaná z akcelerometru .....	28
Obr. 4-2 Příklad dat naměřených pomocí PPG senzoru.....	29
Obr. 4-3 Příklad neúplných dat .....	30
Obr. 4-4 Upravená data z akcelerometru.....	31
Obr. 4-5 Boxplot rozptylu SMV ve skupinách W a S.....	34
Obr. 4-6 Boxplot 25% kvantilu SMV ve skupinách W a S.....	35
Obr. 4-7 Boxplot 90% kvantilu SMV ve skupinách W, NREM a REM.....	35
Obr. 5-1 Závislost specifity na počtu neuronů pro jednotlivé učební algoritmy.....	39
Obr. 5-2 Závislost sensitivity na počtu neuronů pro jednotlivé učební algoritmy .....	39
Obr. 5-3 Matice záměn testovací množiny neuronové sítě s jednou skrytou vrstvou .....	40
Obr. 5-4 Matice záměn trénovací množiny neuronové sítě s jednou skrytou vrstvou .....	40
Obr. 5-5 Matice záměn testovací množiny neuronové sítě se dvěma skrytými vrstvami .....	41
Obr. 5-6 Matice záměn trénovací množiny pro data z PPG senzoru .....	42
Obr. 5-7 Matice záměn testovací množiny pro data z akcelerometru .....	43
Obr. 5-8 Průměr sensitivity (TPR) různých učebních algoritmů pro jednotlivé kategorie ...	46
Obr. 5-9 Matice záměn neuronové sítě s jednou skrytou vrstvou pro rozlišení W/NREM/REM.....	46
Obr. 5-10 Matice záměn neuronové sítě s dvěma skrytými vrstvami pro rozlišení W/NREM/REM.....	47
Obr. 6-1 Porovnání parametru TST získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, S).....	50
Obr. 6-2 Závislost TST odhadnutého pomocí klasifikace neuronovou sítí (W, S) na TST vypočteného na základě hodnocení experta .....	50

Obr. 6-3 Porovnání zpoždění počátku spánku vypočítaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, S).....	51
Obr. 6-4 Porovnání hypnogramů sestrojených na základě hodnocení PSG vyšetření expertem a na základě výstupu z neuronové sítě (W, S).....	52
Obr. 6-5 Závislost SE odhadnuté pomocí klasifikace neuronovou sítí (W, S) na SE vypočtené na základě hodnocení experta .....	52
Obr. 6-6 Porovnání parametru TST získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, NREM, REM) .....	53
Obr. 6-7 Porovnání parametru % REM spánku získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, NREM, REM).....	54
Obr. 6-8 Závislost R latency odhadnuté pomocí klasifikace neuronovou sítí (W, NREM, REM) na SE vypočtené na základě hodnocení experta.....	54

## Seznam tabulek

Tabulka 1-1 Délky a procentuální zastoupení jednotlivých fází spánku, pro průměrný 8hodinový spánek [5] .....	14
Tabulka 2-1 Parametry hodnocené u PSG vyšetření [4] .....	20
Tabulka 4-1 Přehled vybraných parametrů .....	34
Tabulka 5-1 Matice záměn pro klasifikaci epoch do dvou kategorií – bdělost (W) a spánek (S) .....	37
Tabulka 5-2 Porovnání výsledků dosažených při klasifikace W a S .....	44
Tabulka 5-3 Příklad matice záměn pro tři kategorie .....	45
Tabulka 5-4 Porovnání výsledků klasifikace s literaturou .....	48

# ÚVOD

Spánkem stráví člověk v průměru 8 hodin denně, prospíme tedy celou jednu třetinu života. Tím je přímo ovlivněna řada funkcí našeho těla, a tedy i kvalita našeho života jako celku. Proto je důležité zajistit tělu dostatečně dlouhý a kvalitní spánek, avšak řada lidí dnes trpí nespočtem chorob spojených se špatnou kvalitou spánku. Analýza a hodnocení kvality spánku proto nabývá čím dál více na významnosti.

K vyhodnocení kvality spánku se využívá hypnogramu, který ukazuje zastoupení jednotlivých fází spánku během noci. Nejpresnější metodou k získání hypnogramu je polysomnografie (PSG), což je odborné celonoční vyšetření. To musí být podstoupeno ve specializované laboratoři a je při něm sledována řada biosignálů, např. EKG, EOG, EEG a další. Kvůli tomu je náročné jak časově, tak psychicky vzhledem k velkému množství potřebných senzorů připevněných na těle během vyšetření. Alternativou k polysomnografickému vyšetření je aktigrafie, což je metoda dlouhodobého snímání pohybové aktivity pomocí speciálního zařízení připevněného na zápěstí. Její hlavní nevýhodou je nízká specifita, kvůli náročnosti odlišení spánku a klidových aktivit, jako je například čtení, či sledování televize.

Tato bakalářská práce se bude zabývat automatickým rozlišením spánku a bdění z dat naměřených pomocí chytrých hodinek Apple Watch. Pomocí těchto hodinek byly naměřeny dva signály. Jednalo se o změnu zrychlení ve třech osách (x, y, z) naměřenou pomocí akcelerometru a o tepovou frekvenci získanou pomocí faloletismografického (PPG) senzoru. Cílem práce je rozlišení spánku a bdění pomocí neuronové sítě, vyhodnocení kvality spánku s využitím výstupu neuronové sítě a porovnání výsledku automatické metody se standartním postupem dle Americké Akademie Spánkové Medicíny.

V posledních letech dochází k čím dál většímu rozšíření chytré elektroniky (např. chytré hodinky), která uživatele nijak neomezuje při získávání dat. Díky těmto zařízením máme k dispozici velká množství dat, která je ale třeba analyzovat. Proto, dle mého názoru, výrazně roste potenciál hodnocení kvality spánku a její následné zlepšování.

# 1. FYZIOLOGIE SPÁNKU

## 1.1 Biologický rytmus

Během evoluce se život na zemi adaptoval na rytmicky se opakující podněty jako střídání dne a noci nebo střídání ročních období. Velká řada fyziologických pochodů se těmto podnětům přizpůsobila. Tyto rytmy můžeme dělit v závislosti na délce periody na:

1. ultradiánní – perioda významně kratší než 24 hodin
2. cirkadiánní – perioda přibližně 24 hodin
3. infradiánní – perioda výrazně delší než 24 hodin

Pro nás je v tuto chvíli nejdůležitější cirkadiánní rytmus s periodou přibližně jeden den. [1] Tento rytmus řídí naši každodenní potřebu spánku, je generovaný endogenně a řízen pomocí biologických hodin. Ve většině buněk organismu se nachází mechanismus, který řídí biologické hodiny buňky. [2] [3] Tyto jednotlivé hodiny tvoří spolu s centrálními hodinami (master clock) jeden časový systém. Master clock je umístěn v suprachiasmatickém centru (SCN) a reguluje hodiny umístěné na periferii. Centrální hodiny tvoří pouze shluk asi 20 tisíc neuronů v SCN v hypothalamu přímo nad křížením očních nervů. Tato poloha je klíčová jak pro příjem informací z vnějšího prostředí pomocí očních nervů, tak pro možnost přijímat informace z vnitřního prostředí mozku.

Hlavní funkcí centrálních hodin je nejen vytváření a udržování cirkadiánního rytmu i v neperiodickém prostředí, ale i synchronizace rytmů v závislosti na střídání dne a noci.

## 1.2 Fáze spánku

Jednotlivé fáze spánku dnes dělíme podle standardu Americké Akademie Spánkové Medicíny (AASM) do pěti skupin (fází) [4]:

- **W** – Fáze bdění, člověk je ve stavu plného vědomí.
- **N1** – Fáze nejlehčího NREM (tj. fáze spánku bez rychlého pohybu očí) spánku, jedná se o přechod mezi bděním a spánkem. Člověka je možno v tomto stavu jednoduše probudit. Ve fázi N1 se vyskytují pomalé oční pohyby a svalová aktivita vykazuje nižší hodnoty oproti bdělosti. Mohou se zde objevovat nekontrolovatelné trhavé pohyby svalů (Hypnic jerk).
- **N2** – Fáze spánku hlubšího než v N1. Oční bulvy se již nepohybují, mozková aktivita se zpomaluje. Na EEG převažují vlny theta s nižší frekvencí (4–7 Hz) a také specifické shluky vln o charakteristické frekvenci (12–14 Hz) známá jako spánková

vřetena. Objevují se zde také k-komplexy. Tepová frekvence se v této fázi začíná zpomalovat a svalová aktivita mizí.

- **N3** – Fáze hlubokého spánku. Oční bulvy se nepohybují a svalová aktivita je na velmi nízké úrovni. Na EEG se nachází vlny delta o nízké frekvenci (0,5–4 Hz). V této fázi může být těžké jedince probudit.
- **fáze REM** – Jinak také označovaná jako fáze R spánku. Pojmenována podle rychlého pohybu, který vykonávají v této fázi oči (Rapid Eye Movement). Z názvu již vyplývá, že nejvýraznějším znamením této spánkové fáze jsou rychlé pohyby očí detekovatelné pomocí EOG. Mozková aktivita v této fázi může připomínat fázi N1, nebo dokonce bdělost. V této fázi se také zdá většina snů. Svalová aktivita se však v této fázi nenachází.

**Tabulka 1-1 Délky a procentuální zastoupení jednotlivých fází spánku, pro průměrný 8hodinový spánek [5]**

Spánková fáze	Trvání [min]	Procentuální zastoupení
N1	6–10	1 %
N2	220	45–50 %
N3	100	20 %
REM	160	25 %

### 1.3 Spánkový cyklus

Spánkové fáze se během spánku periodicky opakují v cyklech. Běžně člověku trvá jeden cyklus 90–120 minut. [4]


První fází je krátká perioda fáze N1, do které jedinec přechází z bdělého stavu. V této fázi začíná tělo relaxovat a následně postupně přechází do fáze N2. Fáze N2 je také označována jako lehký spánek. Průměrný jedinec touto fází stráví největší podíl noci, přibližně 40–60 % spánku probíhá právě v této fázi.

V následující fázi N3 nastává hluboký spánek. Nastává výrazné zpomalení mozkové činnosti a uvolnění kosterního svalstva. Tato fáze je výrazně kratší než N2 a představuje asi 5–15 % celkové doby spánku.

Spánkový cyklus je zakončen REM fází. Tato fáze je charakteristická rychlými očními pohyby. Mozek je v REM fázi velmi aktivní a vykazuje aktivitu jako při bdělosti, avšak svaly jsou stále uvolněny. Celkový čas strávený v REM fázi je mezi 20–25 %.

Tento cyklus se během jedné noci několikrát opakuje. První cyklus noci může zcela postrádat fázi REM, nebo doba trvání REM fáze během prvního cyklu je velmi krátká. Postupně se během noci čas strávený v REM spánku v každém cyklu prodlužuje. Procentuální zastoupení jednotlivých fází spánku a jejich průměrnou délku (pro 8hodinový spánek) je vidět v Tabulka 1-1.

Celkový průběh spánkových cyklů můžeme zobrazit pomocí hypnogramu (příklad na Obr. 1-1).



Obr. 1-1 Příklad hypnogramu [6]

## 1.4 Poruchy spánku

V této kapitole jsou zohledněny některé spánkové poruchy, které mohou ovlivnit výsledky hodnocení kvality spánku z aktigrafických dat. Tyto nemoci ovlivňují spánek, avšak na záznamu z aktigrafu je není možné rozlišit.

### Insomnie

Insomnie neboli nespavost je nejčastější porucha spánku. Projevuje se buď problémy s usínáním, nebo častým probouzením v noci. Spánek se tak stává nekvalitní a neposkytuje dostatečný odpočinek. Definovat insomnii můžeme na základě frekvence jejího výskytu, doby trvání problémů, podle druhu obtíží a jejich vlivu na pacienta následující den. Nejjednodušeji můžeme insomnii dělit na krátkodobou a dlouhodobou. [4] [5]

Pokud člověk trpí nespavostí a nemůže spát, ale přesto leží nehybně v posteli a snaží se usnout, tak tuto skutečnost není možné odlišit od spánku. Data z akcelerometru budou mít totiž totožný tvar jako v průběhu spánku.

#### Krátkodobá insomnie (transient psychophysiological insomnia)

Akutní insomnie většinou trvá od několika nocí až po několik týdnů, maximálně však 3 měsíce. Akutní nespavost je vyvolána nějakým stresovým faktorem a je zde předpoklad, že porucha zmizí. Nástup poruchy je velmi náhlý a bývá doprovázen obavami, smutkem, depresí, gastrointestinálními příznaky, bolestí hlavy a poruchami koncentrace. Při dlouhodobém působení stresorů může dojít k přechodu od akutní do chronické formy.

### **Dlouhodobá primární insomnie (chronic insomnia)**

Dlouhodobá insomnie trvá nejméně jeden měsíc a její podstatou je zvýšený práh probuditelnosti. Vyskytují se zde také vnucené asociace zabraňující spánku (čím víc chce nemocný usnout, tím víc to nejde). Je doprovázena špatným pocitem vznikajícím z nekvalitního spánku, se kterým přichází úbytek energie, zhoršení koncentrace a nálady. Pro vznik dlouhodobé insomnie je charakteristické, že pacienti měli historicky mělký spánek a onemocnění bylo následně vyvoláno nějakým dalším faktorem. Charakteristickými vyvolávacími faktory jsou stres, životní změny, obavy o zdraví nebo ztráta životní pohody.

Neléčená primární insomnie může přetrvávat roky i po odeznění vyvolávacích faktorů. Neléčená poté může vyvolávat deprese, nebo způsobit nadužívání léků na spaní.

V případě aktigrafických dat je velmi náročné rozlišit spánek a stav, kdy jedinec pouze leží a snaží se usnout.

### **Narkolepsie**

Narkolepsie se vyznačuje stavy spánku opakujícího se několikrát během dne. Jejich trvání je zpravidla krátké (5-10 minut). Objevují se v klidu při stereotypní monotónní činnosti. Narkolepsie bývá doprovázena spánkovou obrnou (40–80 % nemocných). Jedná se o stav nemožnosti jakéhokoliv pohybu. Většinou se objevuje během usínání nebo po probuzení. Stav je doprovázen nepravidelností dechové a tepové frekvence.

Spánek v průběhu noci je u pacientů trpících narkolepsií velmi neklidný, je spojený s častými bizarními sny. Je přerušován častým buzením. Někteří nemocní trpí až insomnií.

Spánek v průběhu dne je velmi obtížné rozlišit od jiné monotónní aktivity (například četby knihy) a proto nebývá běžně aktigrafem detekován jako spánek.



## 2. STANDARTNÍ METODY MONITOROVÁNÍ SPÁNKU

### 2.1 Dotazníky a škály

Dnes je k dispozici několik škál a dotazníků k subjektivnímu posouzení kvality spánku. Tyto dotazníky nejsou normované a slouží spíše k hodnocení vývoje určité choroby v čase.

Jednou z nejpoužívanějších škál je Epworthovská škála spavosti, která slouží k subjektivní kvantifikaci míry denní spavosti. Zachycuje tedy tendenci k spánku během celého dne za poslední týden. [5]

### 2.2 Spánkové deníky

Jednoduchým záznamem spánku jsou také spánkové deníky (viz příklad na Obr. 2-1). Většinou se jedná pouze o jednoduchý formulář, který zkoumaný jedinec vyplní každý den hned po probuzení. Záznamy mohou obsahovat informace jako kdy šel člověk spát, kdy usnul, kolikrát se probudil nebo jak se cítil během noci. Všeobecně jsou spánkové deníky považovány za subjektivní hodnocení.

Jméno\_\_\_\_\_ Identifikační číslo\_\_\_\_\_ Datum\_\_\_\_\_ Pořadí administrace\_\_\_\_  
Spánkový deník, list. č.\_\_\_\_

Datum	___.	___.	___.	___.	___.	___.	___.
Čas ulehnutí do postele (udávejte předchozí noc)	__:	__:	__:	__:	__:	__:	__:
Odhadovaný čas usnutí (nesledujte hodiny)	__:	__:	__:	__:	__:	__:	__:
Čas probuzení	__:	__:	__:	__:	__:	__:	__:
Čas opuštění postele	__:	__:	__:	__:	__:	__:	__:
Kolikrát jste se předchozí noci probudil/a?							
Kolik minut trvalo, než jste znovu usnul/a?							
Kolik minut trval spánek do prvního probuzení?							
Kolikrát jste si šel/šla během dne lehnout?							
Kolik minut jste během dne prospal/a?							
Kolik káv jste vypil/a?							
Jak dobře jste se vyspal/a? (1-5, jako ve škole)							
Na kolik byl spánek dostatečný? (1-5, jako ve škole)							
Jak svěže jste se po probuzení cítil/a? (1-5)							
Jak jste se ráno cítil/a? (1-5, jako ve škole)							
Pil/a jste alkohol před spaním?	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne
Probudil/a jste se dříve, než zazvonil budík?	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne	ano/ne
Užil/a jste lék na spaní? (jaký)							
Stalo se v noci něco zvláštního/neobvyklého? (co)							

Obr. 2-1 Vzor spánkového deníku FN Brno [7]

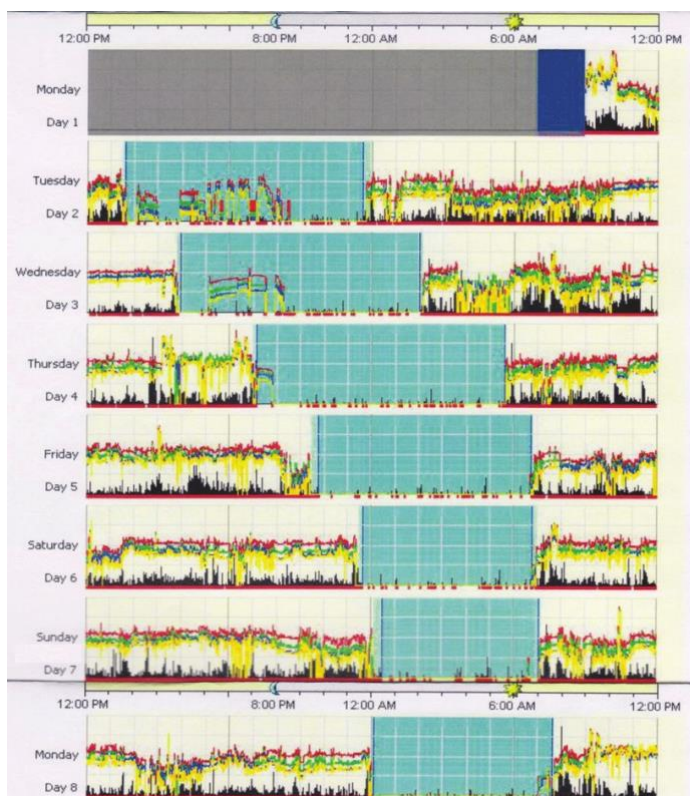
### 2.3 Aktigrafie

Další vyšetřovací metodou pro záznam spánku je aktigrafie. Jedná se o několikadenní monitoraci pohybové aktivity, která je snímána pomocí akcelerometru. Akcelerometr snímá

zrychlení v různých osách. Zrychlení je poté převedeno na počet pohybů za daný časový úsek. Příklad takto získaných dat je vidět na Obr. 2-2. Aktigraf má podobu náramku, který je nošen na nedominantní ruce po dobu několika dnů až týdnů. Výstupem měření je grafické zobrazení počtu pohybů ve zvolených intervalech. Interpretace vychází z předpokladu, že ve spánku nejsou žádné, nebo málo pohyby. Zatímco ve stavu bdělosti jsou pohyby přítomny.

Výhodou tohoto způsobu monitorování spánku je jednoduchost a dlouhodobost měření. Vzhledem k faktu, že během měření nemusí být pacient přítomný ve spánkové laboratoři a k samotné jednoduchosti měření je aktigrafie vhodná zvláště pro pacienty, kteří z nějakého důvodu nemohou podstoupit detailní polysomnografické (PSG) vyšetření.

Hlavní nevýhodou měření kvality spánku pomocí aktigrafie je nízká specifita [8]. Například je velmi těžké z aktigrafických dat rozhodnout, zda daný jedinec leží a čte knihu, nebo spí. Obě aktivity vykáží stejnou aktivitu na akcelometru, avšak z hlediska hodnocení spánku je pouze jedna relevantní. Z tohoto důvodu bývá aktigrafické měření doprovázeno také spánkovými deníky. Popřípadě se některé aktigrafy vyrábějí i se senzory sledujícími intenzitu okolního osvětlení nebo i tepovou frekvenci pro lepší identifikaci stádií spánku. [9]




**Obr. 2-2 Příklad nasnímaných dat pomocí aktigrafu [10]**

## 2.4 Polysomnografie (PSG)

Polysomnografie je neinvazivní vyšetřovací metoda, která shromažďuje fyziologické parametry během spánku. Výsledkem je polysomnogram, což je záznam všech parametrů, které byly získány během měření. Mezi základní parametry, které se měří, patří elektroencefalografie (EEG), elektromyografie (EMG) a to hlavně v oblasti svalů brady a elektrokardiografie (EKG). Mezi další zaznamenávané parametry patří například saturace krve kyslíkem, pohyby těla, dýchací pohyby. Polysomnografické vyšetření probíhá ve speciální spánkové laboratoři a trvá celou noc. Během vyšetření bývá pořizován také audiovizuální záznam, z kterého lze vyvodit pohyby pacienta i vydávané zvuky.

Postup hodnocení vyšetření je standardizován. Spánková stadia se hodnotí po tzv. epochách. Délka těchto epoch bývá většinou 30 sekund. V určitých případech se volí délka 20 sekund. Pro určení spánkových stádií je EEG hodnoceno ze základních svodů A1-C4 nebo A2-C3.

PSG vyšetření je nyní nejkomplexnější metodou v oblasti hodnocení kvality spánku. Avšak i přes fakt, že se jedná o neinvazivní metodu, množství senzorů, které je na vyšetřovaného připevněno a nutnost strávit noc ve spánkové laboratoři může působit jistý diskomfort [11]. Příklad souboru naměřených dat je zobrazen na Obr. 2-3.



Obr. 2-3 Příklad biosignálů naměřených během PSG vyšetření [12]

## Kritéria hodnocení kvality spánku u PSG vyšetření

Po skončení PSG vyšetření je vytvořena zpráva založená na výsledných parametrech. Parametry hodnocené v těchto zprávách vycházejí z doporučení uvedených v manuálu Americké akademie spánkové medicíny (AASM). Názvy a popis významných parametrů PSG vyšetření jsou uvedeny v tabulce: Tabulka 2-1.

**Tabulka 2-1 Parametry hodnocené u PSG vyšetření [4]**

Název parametru	Popis
Lights out	Začátek studie, čas, od kterého se pacient snaží usnout. V tuto chvíli jsou již omezeny všechny podmínky, které mohou rušit pacienta od snahy usnout.
Lights on	Konec studie, čas, ve který technik vchází do místnosti a probouzí pacienta.
Celkový čas záznamu (TRT)	Celkový čas v minutách, doba mezi Lights out a Lights on.
Celkový čas spánku (TST)	Celkový čas, který pacient během studie strávil ve stavu spánku. Tento parametr může být vypočítán součtem času stráveným v jednotlivých fázích spánku.
Efektivita spánku (SE)	Poměr celkového času záznamu a celkového času spánku. $SE = TST/TRT$
Celkový čas strávený vzhůru (TWT)	Celkový čas, po který byl pacient během studie vzhůru.
Procento fáze R (% Stage R)	Procentuální vyjádření času stráveného v R (REM) fázi spánku. $\% Stage R = (Celkový\ čas\ v\ R\ fázi)/TST$ Pro zdravého pacienta by mělo být přibližně $\% Stage R = 25 \%$
Počátek spánku (Sleep Onset)	Čas po Lights out, ve kterém se poprvé objeví spánek. Běžně bývá označen jako první úsek fáze N1.
Zpoždění začátku spánku (Sleep Latency)	Čas v minutách mezi Lights out a Sleep Onset. U studií MSLT (Multiple sleep latency test), které jsou zaměřené na diagnózu narkolepsie jsou také vypočítávané statistické parametry jako medián Sleep Latency nebo průměrná Sleep Latency.
Zpoždění začátku fáze R (Stage R latency)	Čas v minutách mezi počátkem spánku a nástupem první R fáze.
Probuzení po počátku spánku (WASO)	Celkový čas v minutách strávený vzhůru po první epoze spánku. $WASO = TRT - TST - Sleep\ Latency$

## 3. HODNOCENÍ SPÁNKOVÝCH DAT

### 3.1 Manuální hodnocení spánkových dat

Manuální hodnocení kvality spánku probíhá na základě ručního vyhodnocení polysomnogramu. Prvním krokem k hodnocení spánkové studie je rozdělení spánku na jednotlivé fáze. K tomuto se využívá několik naměřených signálů.

Základem je vyhodnocení **EEG**. Amplituda, frekvence a popřípadě i tvar vln pomáhá určit v jaké spánkové fázi se jedinec nachází. EEG také slouží k detekci EEG arousalů, což je zvýšení frekvence EEG trvající minimálně 3 vteřiny. Arousaly mohou vzniknout v návaznosti na nějaký druh fyziologické aktivity, například pohyb končetinou, dýchací problém, nebo vznikají v závislosti na vnější podmět.

Dále se vyhodnocují **EOG** data. Oční rohovka má kladný náboj oproti sítnici. Z tohoto důvodu způsobuje pohyb očí změny ve tvaru EOG záznamu. Rychlé pohyby očí probíhají v R (REM) fázi spánku.

**EMG** je záznam svalové aktivity. Mnoho spánkových poruch je charakterizováno pohybem určité skupiny svalů během spánku. U EMG není potřeba identifikovat konkrétní tvary vln, ale je třeba zaměřit pozornost na změny amplitudy. EMG je většinou měřeno na bradě a na horních a dolních končetinách.

**EKG** je záznam srdeční aktivity. Pro určení fáze spánku nemá velký význam. U EKG křivky je zkoumána její reakce na různé dýchací problémy v průběhu měření. Záznam EKG má význam také z hlediska bezpečnosti pacienta v případě srdečních obtíží.

**Záznam dechové křivky** je využíván hlavně pro detekci spánkové apnoe nebo hypopnoe. Saturace kyslíku v krvi (**SpO<sub>2</sub>**) je dalším parametrem, který se měří. Je měřen pomocí pulzního oximetru. SPO<sub>2</sub> je měřeno hlavně kvůli detekci dýchacích problémů a pro zajištění bezpečnosti pacienta.

Za pomoci těchto parametrů je spánek rozdělen do jednotlivých fází, dále jsou vypočítány parametry hodnotící spánek a je zhodnocen výskyt artefaktů (K-komplexy, arousaly, ...) vzniklých v průběhu měření. [4]

Hlavní nevýhodou manuálního hodnocení polysomnografických dat je čas nutný k tomuto vyhodnocení. Standardní PSG měření trvá zhruba 8 hodin, které je nutné zaznamenat a následně vyhodnotit. Vhodné je zejména pro vyhodnocování určitých specifických chorob, nebo pro vyhodnocení konkrétního úseku signálu, který je z nějakého důvodu důležitý pro diagnózu.

### 3.2 Automatické hodnocení spánkových dat

Automatické hodnocení spánkových dat může představovat velké zjednodušení pro specializované lékaře. Metody automatického hodnocení nejen zjednoduší práci odborníkům, kteří nebudou muset manuálně procházet celý několikahodinový záznam spánku, ale také sjednotí práci těchto odborníků. Rozdíl v hodnocení mezi jednotlivými odborníky se totiž může lišit [13]. Nejčastěji používané metody automatického hodnocení dat, založené na tzv. strojovém učení, jsou uvedeny níže.

#### Umělá neuronová síť


Umělé neuronové sítě jsou modely, které se svojí strukturou snaží podobat lidskému mozku. Struktura umělé neuronové sítě se podobá té lidské. Je tvořena jednotlivými výkonnými prvky – neurony. Lidské neurony se skládají z několika základních částí, a to ze samotného těla neuronu, dendritů, axonů a synapsí. Tyto základní části zodpovídají za příjem, přenos, uchování a zpracování signálu. Stejně tak jsou i umělé neuronové sítě založeny na principu příjmu, zpracování a přenosu signálu.

Základním matematickým modelem je umělý neuron, který imituje funkci biologického neuronu. Umělý neuron má  $n$  vstupů  $x_1, x_2 \dots x_n$ , které představují vstupní signály (dendrity u reálného neuronu). Tyto signály vstupují do aktivační funkce  $f$ , kde je následně každý signál násoben příslušnou vahou  $w_1, w_2 \dots w_n$ , které představují různou důležitost jednotlivých vstupů. Od součtu všech součinů vstupů a vah je následně odečtena hodnota prahu, což je vidět v rovnici (3.1).

$$y = f \left[ \sum_{i=1}^N w_i x_i - \theta \right] \quad (3.1)$$


kde  $f$  značí aktivační funkci,  $w$  je hodnota váhy,  $x$  je vstupní signál,  $\theta$  je práh

Velký význam na výsledný signál  $y$  má použitá aktivační funkce. Nejběžněji používané aktivační funkce jsou zobrazeny na Obr. 3-1.



Obr. 3-1 Příklady obvyklých aktivačních funkcí

Umělá neuronová síť vzniká paralelním spojením několika neuronů. Takto vzniklá vrstva M paralelně pracujících neuronů se nazývá jednovrstvý perceptron. Spojením několika vrstev perceptronů vzniká neuronová síť. Z každého neuronu v dané vrstvě vedou spoje do všech neuronů ve vrstvě nadcházející. Každá neuronová síť se skládá z minimálně dvou vrstev, a to z vrstvy vstupní a vrstvy výstupní. Většinou je však mezi tyto vrstvy vložena ještě další, skrytá vrstva. Do skryté vrstvy přichází signál ze vstupní vrstvy, je zpracován a poslán dál do výstupní vrstvy. Skrytých vrstev může být v neuronové síti několik. Na Obr. 3-2 je zobrazena neuronová síť s jednou skrytou vrstvou.



**Obr. 3-2 Příklad topologie neuronové sítě**

## Učení neuronové sítě

Cílem učení neuronové sítě je nastavení parametrů modelu pro dosažení co nejlepších výsledků (např. pro dosažení co největší úspěšnosti klasifikace). Učení neuronové sítě je možné rozdělit na učení s učitelem a na učení bez učitele. Metody učení s učitelem, které jsou zde používány, jsou založeny na principu porovnávání očekávaného výstupu (získaný pomocí zlatého standardu, například hodnocením experta) se skutečným výstupem modelu, tedy aby:

$$y = d \quad (3.2)$$

kde  $y$  je skutečný výstup modelu a  $d$  je očekávaný výstup modelu

Pokud se tedy  $y$  nerovná  $d$  je chyba na výstupu větší než nula (tato chyba bývá kvantifikována jako střední kvadratická odchylka – MSE), dojde ke změně vah a prahů. K této korekci je možné využívat velké množství metod. Pro nastavování parametrů jednotlivých neuronů je možné využívat delta pravidlo:

$$\delta = d - y \quad (3.3)$$

Samotné učení probíhá v epochách, kdy je v každé epoše vypočítána hodnota  $\delta$  a pomocí ní dojde k přizpůsobení vah a prahů. Pro učení celé neuronové sítě je základní metodou optimalizace vah a prahů metoda gradientního sestupu. Kdy je hledáno minimum funkce pomocí výpočtu


gradientu. Gradient udává směr nejstrmějšího růstu chyby, proto je postupováno proti směru gradientu. K úpravě vah a práhů poté dochází pomocí vzorců (3.4), (3.5).

$$w_i(t+1) = w_i(t) + \mu \delta x_i \frac{\partial f(a)}{\partial a}, \forall i \quad (3.4)$$

$$\theta(t+1) = \theta(t) - \mu \delta \frac{\partial f(a)}{\partial a} \quad (3.5)$$

kde  $w$  je hodnota váhy,  $\theta$  je práh,  $\mu$  je konstanta učení

Změnou velikosti konstanty učení se mění rychlost, jakou je dosaženo maximální přípustné odchylky  $\delta$ . Nastavením příliš nízké hodnoty  $\mu$  dochází k příliš pomalé konvergenci, avšak nastavením příliš vysoké hodnoty  $\mu$  může dojít k divergenci od optimálního výsledku, viz Obr. 3-3. Konstanta učení může dosahovat hodnot  $0 < \mu < 1$ . Učení probíhá dokud není dosaženo maximálního počtu epoch, pokud je již dosaženo maximální přípustné chyby, nebo pokud nebylo nalezeno minimum chybové funkce ( $\text{grad}(E) \approx 0$ ). Nevýhodou využití metody gradientního poklesu je zastavení učení při nalezení lokálního minima. [14][15]



Obr. 3-3 Příklady různě zvolených velikostí  $\mu$

## K-means shlukování (metoda k-středů)

Metoda k-means je nehierarchická shlukovací metoda, kdy je dopředu znám výsledný počet shluků, do kterých se data rozdělují. Každý shluk je reprezentován svým geometrickým středem – centroidem.

Na počátku je matice získaných dat, která jsou vhodně upravena (viz kapitola 4.3). Následně musí být vybrán vhodný počet shluků a je nastaven korespondující počet centroidů. Výchozí pozice těchto centroidů je nastavena náhodně. Poté dochází k realizaci samotného shlukování. Je



vypočítána vzdálenost mezi všemi objekty a jednotlivými centroidy. Každý objekt je přiřazen ke shluku, jehož centroid je nejbližší (euklidovská vzdálenost mezi centroidem a např. středem shluku je co nejmenší). Následně jsou přepočítány souřadnice každého centroidu, aby byl opět geometrickým středem každého shluku. Shlukování se opakuje, dokud dochází ke změnám pozic centroidů, nebo není dosaženo přípustné odchylky.

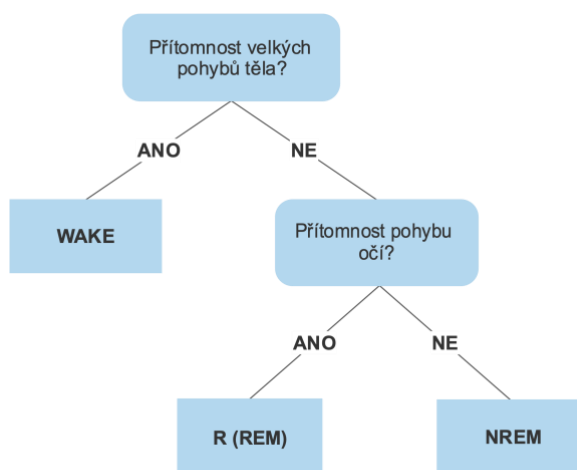
Výsledek shlukování je závislý na výchozích souřadnicích centroidů. Z tohoto důvodu bývá algoritmus několikrát opakován s různými počátečními souřadnicemi.

## Náhodný les

Náhodný les (random forrest) je klasifikační metoda založená na principu velkého množství rozhodovacích stromů a následného vybrání nejčastějšího výsledku (modulo z výsledků všech rozhodovacích stromů).

Rozhodovací strom je model obráceného stromu, kde se na samotném vrcholu stromu nachází kořen. Tento kořen představuje první uzel. Každý uzel značí jednu otázku – jeden krok v rozhodovacím procesu. Kořen se poté větví na samostatné větve. Na konci každé větve se nachází další uzel s otázkou. Po dosažení posledního uzlu je na základě odpovědi na otázky predikována kategorie. Model rozhodovacího stromu, kde dochází k rozhodování na základě naměřených hodnot a zvolených prahů je vidět na Obr. 3-4.

Náhodný les je složen z několika rozhodovacích stromů, kde každý strom vzniká na základě náhodného výběru několika zvolených atributů z učební množiny.



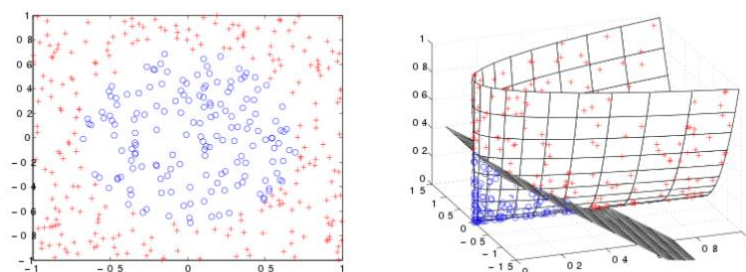
Obr. 3-4 Model jednoduchého rozhodovacího stromu

## Metoda podpůrných vektorů

Metoda podpůrných vektorů (Support Vector Machines) patří do kategorie jádrových algoritmů (kernel machines). Jedná se o metodu pro binární klasifikaci dat, kterou je možné použít jak pro lineárně, tak pro nelineárně separovatelná data. U nelineárně separovatelných dat je základním principem převod vstupního prostoru do jiného, vícedimensionálního prostoru, ve kterém lze třídy oddělit lineárně do dvou poloprostorů. Tomuto hledání vhodné hyperroviny se říká kernel trick a provádí se na základě jádrové funkce. Kernel trick je znázorněn na Obr. 3-5, kde na levé polovině jsou vidět dvě skupiny dat, které nelze lineárně rozdělit. Na pravé polovině obrázku jsou data převedena do jiného prostoru, ve kterém je lze lineárně rozdělit pomocí roviny.

V případě nemožnosti lineárního oddělení se hledá taková hyperrovina, ve které bude docházet k co nejmenší chybě klasifikace. Pro nalezení hyperroviny je využito podpůrných vektorů. Samotné učení je, stejně jako neuronové sítě, založeno na minimalizaci chyby klasifikace.

Metodou podpůrných vektorů je možno rozdělit data pouze do dvou skupin. Pro klasifikaci více skupin mohou být použity různé přístupy. Prvním přístupem je metoda one-versus-all, kdy SVM odliší jednu skupinu od ostatních. Jiný přístup je metoda one-versus-one, kdy klasifikátor rozlišuje různé dvojice a jako finální výsledek je vybrána skupina s nejvyšším součtem skóre napříč jednotlivými dvojicemi. [16]



Obr. 3-5 Kernel trick příklad [17]

## 4. ZPRACOVÁVANÁ DATA

Data zpracovávaná v této bakalářské práci pocházejí ze studie Michiganské univerzity nazvané Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. [6] Data byla sbírána v letech 2017–2019. Celkem se studie zúčastnilo 39 osob a byly získány úplné záznamy aktivity od 31 z nich.

### 4.1 Protokol měření

Všech 39 zúčastněných osob muselo potvrdit písemný informovaný souhlas. Součástí informovaného souhlasu bylo také potvrzení, že účastník nemá diagnostikováno něco z následujícího: syndrom neklidných nohou, poruchy dechu spojené se spánkem, insomnií, parasomnií, hypersomnií, kardiovaskulární choroby (kongestivní selhání srdce, ischemická choroba srdeční, infarkt myokardu nebo nějaký druh srdeční arytmie), poruchy zraku bez možnosti korekce pomocí brýlí anebo jiná porucha, která má významný vliv na funkci mozku. Dále byli ze studie vyloučeni účastníci, kteří v posledním měsíci letecky cestovali přes více jak dvě časová pásma a kteří pracují ve směnném provozu. Nadměrná denní spavost by také měla vliv na výsledné měření. Tato porucha byla vyloučena pomocí Epworthovské škály denní spavosti, kdy byli vyloučeni účastníci, kteří dosáhli skóre vyššího než 10.

Vybraní účastníci studie poté obdrželi chytré hodinky Apple Watch (Series 2 a 3, Apple Inc.), které nosili v průběhu 7 až 14 dnů, s přerušením pouze na nabíjení. Data naměřená pomocí Apple Watch byla odesílána do telefonu, ze kterého byla nahrávána na server.

Poslední noc měření byli účastníci podrobeni také osmihodinovému PSG vyšetření. PSG měření bylo provedeno pod dohledem odborníka a vedeno podle technického standardu AASM (s výjimkou oronasálního termistoru a senzoru nosního tlaku). Bylo využito měření pomocí EEG, EOG, bradového EMG, hrudního a abdominálního plethysmografu (RIP), mikrofonu pro určení ronchopatie, pulzního oxymetru a 2svodového EKG.


Elektrofyzilogické signály prvních osmi pacientů byly měřeny přístrojem Vitaport 3 (TEMEC Instruments B.V.), všechny ostatní signály byly poté naměřeny přístrojem Graiel HD-PSG/EEG (Compumedics). Pro vizuální hodnocení PSG vyšetření bylo využito kritérií AASM. Vzhledem k nepřítomnosti oronasálního termistoru a převodníku nosního tlaku bylo pro určení apnoe využito pletysmografů.

Během měření PSG stále pokračoval záznam pomocí Apple Watch, ale byly pozměněny parametry měření. Spuštěním měřicího programu ‚trénink‘ byla snížena vzorkovací frekvence záznamu tepu na měření každých 5 vteřin.

## 4.2 Popis naměřených dat


Data naměřená pomocí chytrých hodinek Apple Watch pocházejí ze dvou senzorů. Prvním je tříosý MEMS akcelerometr od firmy STMicroelectronics (LSM6DS3 always-on 3D akcelometr). Akcelerometr je používán pro záznam zrychlení (pohybu). Měřicí rozsah je v rozmezí  $\pm 16 \text{ g}$  ( $\text{m}\cdot\text{s}^{-2}$ ). [19] Data získaná z tohoto senzoru jsou ve formátu tří vektorů, které reprezentují zrychlení v osách x, y a z. Posledním čtvrtým vektorem je časová osa v sekundách datovaná od 1. ledna 1970. Tato časová osa (stejně tak časová osa u dat tepové frekvence) je již v databázi předzpracovaná na čas v sekundách od začátku snímání pomocného PSG vyšetření. Vzorkovací frekvence akcelerometru může být změněna vývojářem aplikace pro sběr dat. V případě této studie byla nastavena na hodnotu  $f_{vz} = 50 \text{ Hz}$ .

Na Obr. 4-1 vidíme příklad dat získaných pomocí akcelerometrického senzoru. Čas 0 zde odpovídá začátku simultánně snímaného PSG vyšetření. Jelikož je senzor umístěn na zápěstí, není možné určit v jaké poloze se právě daný jedinec nachází. Pouze dokážeme určit, že při změně výchylek jednotlivých os (x, y, z) došlo ke změně polohy těla.



**Obr. 4-1 Data získaná z akcelerometru**

Druhým senzorem je optický PPG senzor s infračervenými diodami pro měření tepové frekvence. Ve standardním režimu snímají hodinky tepovou frekvenci každých 200 až 300 vteřin. Vzorkovací frekvence se liší na základě dat o pohybu uživatele. Při vyšší tělesné aktivitě (větší míře pohybu) se vzorkovací frekvence zvyšuje. Tato metoda je zavedena z důvodu snížení spotřeby baterie.



**Obr. 4-2 Příklad dat naměřených pomocí PPG senzoru**

V této práci jsou využívána data naměřená během současného PSG vyšetření a data naměřená několik hodin před vyšetřením. Data naměřená během několika předchozích dnů nebyla volně zveřejněna. Data od času nula (čas začátku PSG vyšetření) téměř neobsahují chybějící data.


Záznam před začátkem PSG vyšetření obsahuje dostatek dat z akcelerometru. Ty části záznamů, kde chyběly výstupy z akcelerometru, nebyly využívány. Tento problém byl podle údajů uvedených v databázi způsoben problémy s nahráváním dat na server. Avšak vzhledem k jinému principu snímání PPG senzorem se zde vyskytuje nedostatečná informace o tepové frekvenci. Nedostatek dat z PPG senzoru byl vyřešen lineární interpolací pro každou vteřinu záznamu.

### 4.3 Předzpracování dat

Pro určení parametrů hodnotících kvalitu spánku bylo nejprve nutné rozlišit spánek (S) a bdělost (W). Případně rozlišit skupiny bdělost W, NREM a REM. Z akcelerometrických dat snímaných ze zápěstí není možné rozlišit v jaké poloze se daný jedinec nachází, protože při vzpřímené poloze těla i při poloze vleže může být zápěstí se snímačem natočeno v jakékoli pozici. Z tohoto důvodu není možné jednoduše rozlišit spánek (ať se jedná o REM, nebo NREM) a bdělost pouze z gravitačního zrychlení v záznamu akcelerometru.

Pro rozlišení jednotlivých skupin bylo použito neuronové sítě a metody SVM. Pro jejich správnou funkci je nutné data vhodně předzpracovat.

Jako první krok předzpracování dat bylo provedeno vybrání vhodných záznamů pro následné zpracování. Byly vyloučeny záznamy, které byly neúplné. U těchto záznamů nebyla zaznamenána data během celého PSG vyšetření, ale záznam byl přerušen. Takto vyloučených záznamů bylo celkem 6. U těchto záznamů nemohou být určeny parametry kvality spánku, avšak data mohou být využita na učení neuronové sítě. Příklad tohoto záznam je zobrazen na Obr. 4-3.



**Obr. 4-3 Příklad neúplných dat**


Pro kvalitní učení neuronové sítě je vhodné mít stejné množství vstupů pro všechny kategorie, které je snaha rozlišit. Využívaná data obsahují větší množství hodnot pro spánek než pro bdělost. Pro rozlišení skupin W a S je vhodné srovnat délky obou skupin. To bylo provedeno prostým zkopírováním hodnot ve stavu bdění a doplněním obou vektorů (W a S) na přibližně stejnou délku. Tato vzniklá množina byla využita pro učení a testování neuronové sítě.

Pro rozdělení dat do skupin W, NREM a REM byla stejným způsobem srovnána délka dat ve všech skupinách a získaná množina byla opět využita pro sestavení sítě.

Dalším krokem bylo předzpracování dat z akcelerometru. Z vektorů x, y a z byl vytvořen pouze jediný vektor, který reprezentuje změnu pohybu v jakékoli ose. Za tímto účel byl vypočítán parametr Signal Vector Magnitude (běžně označován jako SVM, zde značen jako SMV, aby nedošlo k záměně Support Vector Machines). [20]

$$SMV = \sqrt{x_i^2 + y_i^2 + z_i^2} \quad (4.1)$$

Vektor SMV vypočítaný z akcelerometrických dat je vidět vykreslený na Obr. 4-4.



**Obr. 4-4 Upravená data z akcelerometru**

Takto upravená data z akcelerometru a surová data tepové frekvence z PPG senzoru byla poté rozdělena do epoch o délce 30 vteřin bez překryvu.

#### 4.4 Výpočet parametrů ze získaných signálů

V každé epoše byly následně vypočítány parametry používané pro následné zpracování. Prvním byl parametr **SMA** (signal magnitude area) (4.2). SMA je využíván na rozlišení klidu a aktivity [21] [22]. U diskrétního signálu lze spočítat pomocí rovnice (4.2).

$$SMA = \frac{1}{n} \cdot \sum_{i=1}^n (|x_i| + |y_i| + |z_i|) \quad (4.2)$$

kde  $n$  je počet vzorků v epoše signálu

Dalším parametrem vypočítaným v každé epoše byla **energie signálu SMV**, vypočítána podle vzoru uvedeného v [23]. V uvedené práci byla využita pro rozlišení jednotlivých aktivit pomocí akcelerometru.

$$Energie_{SMV} = \frac{\sum_{i=1}^n FFT_{SMV}^2}{n} - \overline{SMV} \quad (4.3)$$

kde  $n$  značí počet vzorků v epoše,  $FFT$  značí diskrétní Fourierovu transformaci,  $\overline{SMV}$  značí průměr z vektoru SMV v dané epoše

### Medián

Pro tepovou frekvenci i pro SMV byl v každé epoše vypočítán medián. Medián je hodnota, která dělí seřazenou řadu na dvě stejné poloviny. Polovina hodnot je tedy větších nebo rovných mediánu a polovina hodnot je menších nebo rovných mediánu.

$$median(a) = a_{(\frac{n+1}{2})}, \text{ pro } n \text{ liché} \quad (4.4)$$

$$median(a) = \frac{x_{(\frac{n}{2})} + x_{(\frac{n}{2}+1)}}{2}, \text{ pro } n \text{ sudé} \quad (4.5)$$

kde  $n$  je počet vzorků  $x_i$  měřeného signálu počet vzorků v epoše

### Směrodatná odchylka

Stejně jako medián byla směrodatná odchylka vypočítána jak u akcelerometrických dat (vektoru SMV), tak u dat získaných z PPG senzoru. Směrodatná odchylka je odmocnina z rozptylu. Rozptyl je průměrný čtverec odchylky od průměru.

$$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.6)$$

kde  $n$  je počet vzorků  $x_i$  měřeného signálu (počet vzorků v epoše),  $\bar{x}$  reprezentuje průměrnou hodnotu vzorků v epoše

### Variační rozpětí

Variační rozpětí je rozdíl mezi největší a nejmenší hodnotou daného souboru. Tento parametr je velmi ovlivněn extrémními hodnotami.

$$R = x_{max} - x_{min} \quad (4.7)$$

kde  $x_{max}$  je největší hodnota v epoše měřeného signálu a  $x_{min}$  je nejmenší hodnota v epoše měřeného signálu

Tento parametr je ovšem velmi ovlivněn odlehlými hodnotami, proto bývá lepší využívat kvartilové rozpětí.



## Kvantil

Kvantil je hodnota, která rozděluje seřazenou řadu na dvě části. P% kvantil rozděluje data na p % hodnot a (100–p) % hodnot. V případě této práce byl vypočítán 10%, 25%, 75% a 90% kvantil.

## Rozpětí kvantilů

Kvantilové rozpětí je rozdíl mezi p% kvantilem a (100–p)% kvantilem. Zde je využito kvartilové rozpětí  $R_q$ , což je rozdíl mezi 75% a 25% kvantilem. Kvartilové rozpětí pokrývá 50 % hodnot. Tento parametr není tak ovlivněn extrémními hodnotami.

$$R_q = x_{0,75} - x_{0,25} \quad (4.8)$$

kde  $x_{0,75}$  je 75% kvantil a  $x_{0,25}$  je 25% kvantil

## 4.5 Standardizace parametrů

Dalším krokem pro správnou detekci spánku je **standardizace** naměřených hodnot, které se budou dále zpracovávat.

Standardizací dojde k převedení proměnných na stejné měřítko, a tudíž nezáleží na skutečných rozměrech proměnné. Zde byla použita standardizace směrodatnou odchylkou, výpočtem tzv. z-skóre (4.9).

$$y_i = z = \frac{x_i - \mu}{\sigma} \quad (4.9)$$

kde  $\mu$  je střední hodnota (průměr) a  $\sigma$  je směrodatná odchylka

## 4.6 Statistická analýza parametrů

Z vypočtených statistických hodnot, energiesmv a SMA byly vybrány parametry, které posloužily pro klasifikaci. Nejprve byly provedeny statistické testy pro ověření rozdílnosti dat v klasifikovaných skupinách. Vzhledem vysokému výskytu odlehlých hodnot byly zvoleny neparametrické testy. Pro rozřazování do dvou skupin byl zvolen Mannův-Whitneyův U test. U rozřazování dat do tří skupin byl pro ověření rozdílnosti ve skupinách využit Kruskalův-Walisův test. [24]

Oba testy (na hladině významnosti  $\alpha = 0,05$ ) potvrdily, že rozdíl mezi klasifikačními skupinami je u všech parametrů statisticky významný. Pro snížení počtu příznaků bylo využito metody krokové (stepwise) regrese. Tímto způsobem byly vyloučeny parametry 25% a 75% kvantilu. Dále byl vyloučen parametr směrodatné odchylky u dat tepové frekvence z důvodu nízké

snímací frekvence před začátkem polysomnografického vyšetření. Z tohoto důvodu by směrodatná odchylka mohla být zavádějící parametr.


Tabulka 4-1 zobrazuje přehled vybraných parametrů.

**Tabulka 4-1 Přehled vybraných parametrů**


Zdroj signálu	Vybrané parametry
Akcelerometr	Energies <sub>VM</sub> , SMA, kvadratický průměr, medián, směrodatná odchylka, 10% kvantil, 90% kvantil, kvartilové rozpětí
PPG senzor	Medián, kvadratický průměr

Porovnání rozložení statistických veličin lze zobrazit pomocí krabicových grafů (tzv. boxploty). Krabicové grafy ukazují variabilitu zobrazeného parametru v jednotlivých skupinách. Střední část diagramu ohraničuje 25% a 75% kvantil a mezi nimi je zobrazen medián. Krajní hodnoty grafu zobrazují minimum ( $x_{0,25} - 1,5 \cdot R_q$ ) a maximum ( $x_{0,75} + 1,5 \cdot R_q$ ). Červeným křížem jsou poté označeny odlehlé hodnoty ležící mimo maximum a minimum.


Boxplot vybraného příznaku (rozptylu SMV) je vidět na Obr. 4-5. Boxplot nevybraného příznaku (75% kvantil) je vidět na Obr. 4-6. Obr. 4-7 poté zobrazuje rozložení 90% kvantilu SMV ve skupinách W, NREM, REM.



**Obr. 4-5 Boxplot rozptylu SMV ve skupinách W a S**



**Obr. 4-6 Boxplot 25% kvantilu SMV ve skupinách W a S**



**Obr. 4-7 Boxplot 90% kvantilu SMV ve skupinách W, NREM a REM**

## 5. KLASIFIKACE SPÁNKU

### 5.1 Klasifikace fází W a S pomocí neuronové sítě

Příznaky vybrané v předchozí kapitole byly využity jako vstup do neuronové sítě pro klasifikaci spánku a bdění. Neuronová síť byla vybrána jako klasifikační metoda vzhledem k příznivým výsledkům u jiných studií [6] [25]. Použití této metody je také výhodné z hlediska možnosti řešení nelineárních problémů. Neuronová síť byla vytvořena v programu Matlab 2020. Data byla náhodně rozdělena na trénovací a testovací set v poměru 80:20. Trénovací set byl dále rozdělen na trénovací a validační množinu. Validační množina dat slouží jako ochrana před případným přeučením neuronové sítě (overfitting). Tato validační množina se během učení nepodílí na nastavování vah a prahů, ale testuje průběh učení. Pokud v průběhu učení dojde ve validační množině ke špatnému určení přednastaveného počtu za sebou jdoucích epoch, dojde k ukončení učení.

#### 5.1.1 Realizace neuronové sítě

Zde využívané neuronové sítě jsou založené na metodě učení s učitelem, tudíž vyžadují matici vstupů (příznaků) a matici požadovaných výstupů, které jsou předem známe. Zde byla matice požadovaných výstupů vektor, ve kterém byly jednotlivé epochy zařazeny do kategorie spánek, nebo bdění. Trénovací matice příznaků se skládá z osmírozměrných příznakových vektorů reprezentujících každou epochu. Data byla rozdělena mezi trénovací, validační a testovací množinu náhodně.

Vytvořená neuronová síť je dopředná. Obsahuje vstupní vrstvu s 8 neurony, jednu, nebo dvě skryté vrstvy a výstupní vrstvu se dvěma neurony. Výstupem byly tudíž dvě hodnoty, kdy větší z nich značila zařazení do dané kategorie (W, S). Nejlepší síť byla vybrána na základě testování. Testování spočívalo v postupném měnění algoritmu učení, kdy byly vybrány algoritmy: Lavenbergův-Marquardtův algoritmus, gradientní sestup, gradientní sestup s adaptivními vahami, algoritmus Scaled conjugate gradient (založen na Lavenberg-Marquardtově algoritmu s adaptivními vahami) a Bayesovská regularizace. Dále byl postupně měněn počet neuronů ve skrytých vrstvách od 10 do 30. Nakonec byly využívány různé metriky stanovení úspěšnosti učení, a to: MSE (střední kvadratická odchylka), SSE (celková kvadratická odchylka) a Crossentropy (křížová entropie). U sítí s jednou skrytou vrstvou byl maximální počet epoch učení nastaven na hodnotu 70. Při zvýšení této hodnoty se již nezlepšuje výsledek učení u většiny algoritmů. U algoritmů založených na gradientním sestupu byla tato hodnota zvýšena na 200 z důvodu pomalejšího učení. Část dat v učební množině byla také vybrána pro validační kontrolu.

Zde byla použita jako kontrola proti přeučení sítě. Maximální počet validačních chyb byl nastaven na hodnotu 10 u sítě s jednou skrytou vrstvou a 5 u dvou skrytých vrstev. Na základě této validační kontroly bylo předčasně ukončeno učení zhruba 5 % neuronových sítí, většinou se jednalo o algoritmy gradientního sestupu.

Takto vytvořené neuronové sítě byly učeny třikrát a výsledné statistické metriky byly spočítány jako průměr. To bylo zavedeno z důvodu snížení vlivu náhodných výchozích hodnot vah a prahů. Na základě výsledné sensitivity (5.1) a specificity (5.2) byla následně vybrána síť s nejlepšími parametry. Nejprve byly z výběru odstraněny sítě se specificitou pod 50 % a poté byla vybrána síť s nejvyšším součtem sensitivity a specificity. Takto byly vybrány sítě s jednou skrytou vrstvou a poté i se dvěma.

Typ metriky pro stanovení úspěšnosti učení téměř neměl vliv na výslednou klasifikaci. Pro jednoduchost byla zvolena MSE.

Ke statistickému zhodnocení efektivity modelu je využívána matice záměn. Vzor matice záměn je zobrazen níže (viz. Tabulka 5-1). Matice záměn umožňuje přehledně zjistit úspěšnost predikce daného modelu.

V následujících podkapitolách je klasifikován spánek do dvou skupin pomocí neuronové sítě, nejprve je využito všech získaných parametrů. Ale vzhledem ke dvěma zdrojům signálu (akcelerometr a PPG senzor) jsou následně data klasifikována pomocí parametrů vypočtených pouze z jednoho signálu. Tento přístup je zaveden pro zjištění míry, s jakou pomáhají parametry vypočtené z jednotlivých signálů klasifikaci. Očekává se větší významnost parametrů vypočítaných z akcelerometru.

**Tabulka 5-1 Matice záměn pro klasifikaci epoch do dvou kategorií – bdělost (W) a spánek (S)**

		Skutečná kategorie		
		W	S	
Predikovaná kategorie	W	Skutečně negativní (TN) Správná predikce W	Falešně negativní (FN) Chybně predikováno jako W	NPV
	S	Falešně pozitivní (FP) Chybně predikováno jako S	Skutečně pozitivní (TP) Správná predikce S	PPV
		Specificita	Sensitivita	Accuracy

Z matice záměn lze poté vypočítat statistické parametry, které jsou důležité k vyhodnocení kvality predikce daného modelu. Vypočítané parametry jsou uvedené níže.

Senzitivita (citlivost) udává úspěšnost určení dané kategorie.

$$Senzitivita = \frac{TP}{TP + FN} \quad (5.1)$$

Specificita určuje podíl skutečně negativních výsledků testu ke všem negativním výsledkům.

$$Specificita = \frac{TN}{TN + FP} \quad (5.2)$$

Další parametr hodnotící úspěšnost určení správné kategorie je pozitivní prediktivní hodnota (PPV), kterou lze spočítat jako podíl skutečně pozitivních výsledků ke všem pozitivním výsledkům. Tato hodnota je nutná k vypočtení  $F_1$  skóre.

$$PPV = \frac{TP}{TP + FP} \quad (5.3)$$

$F_1$  skóre je statistický parametr, který měří celkovou úspěšnost testu v závislosti na sensitivitě a PPV. Tento parametr na rozdíl od celkové úspěšnosti (accuracy) bere v potaz počty vzorků v jednotlivých hodnocených skupinách.  $F_1$  skóre lze spočítat podle vzorce (5.4).

$$F_1 \text{ skóre} = 2 \cdot \frac{PPV \cdot Senzitivita}{PPV + Senzitivita} \quad (5.4)$$

Celkovou úspěšnost (přesnost) hodnocení lze spočítat pomocí vzorce (5.5).


$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (5.5)$$

### 5.1.2 Výsledky klasifikace pomocí neuronové sítě za využití všech parametrů


#### Sítě s jednou skrytou vrstvou

Při využití všech parametrů jsou nejprve vytvořeny neuronové sítě s jednou skrytou vrstvou obsahující 10 až 30 neuronů. Tyto sítě dosahují výsledné specifity v rozmezí od 37 % do 69 % v závislosti na zvoleném algoritmu učení a počtu neuronů ve skryté vrstvě sítě. Sensitivita dosahuje, opět v závislosti na nastavení parametrů, hodnot mezi 85 % až 92 %. Výjimkou byly sítě s algoritmem učení gradientního poklesu s momentem, kde se vzhledem k nevhodně zvoleným parametrům pohybovala sensitivita mezi 63 % až 90 % (např. je nutné správně nastavit tzv. konstantu momenta  $\beta$ , která zde však nebyla uvažována). Výsledné hodnoty jsou vidět na Obr. 5-1 a Obr. 5-2. Úspěšnost určení kategorie (Accuracy) se u většiny sítí pohybovala okolo 75 % až 80 %.  $F_1$  skóre dosahovalo hodnot mezi 46 % a 76 % (s průměrem a směrodatnou odchylkou  $67 \pm 10,9$  %).

V závislosti na výsledné sensitivitě a specifitě se jako nejlepší učební algoritmy jeví Lavenbergův-Marquardtův algoritmus a Bayesovská regularizace. Obě sítě mají vcelku konstantní specifitu, s mírným zlepšením v oblasti mezi 20 až 30 neurony.



**Obr. 5-1 Závislost specifity na počtu neuronů pro jednotlivé učební algoritmy**



**Obr. 5-2 Závislost sensitivity na počtu neuronů pro jednotlivé učební algoritmy**

Na následném Obr. 5-3 je vidět matice záměn při testování zvolené sítě na testovací množině. Výsledná specifita vybrané sítě je 64,7 % a sensitivita je 91,2 %. Problémem sítě je tedy špatná

klasifikace epoch, kdy pacient nespí, ale také se nehýbe a jeho tep také nevykazuje změny. Tyto epochy jsou často určovány jako S (výsledky falešně pozitivní). Naopak u menší části epoch zaznamenaných během spánku dochází k takovému pohybu a tepové frekvenci, že jsou klasifikovány jako W (výsledky falešně negativní). Celková úspěšnost (accuracy) je 79 % a  $F_1$  skóre dosahuje hodnoty  $F_1 = 80,2$  %. Na Obr. 5-4 je vidět matice záměn trénovací množiny. Výsledky jsou velmi podobné testovacím. U neuronové sítě nedošlo k přeučení.

Predikované	W	2601 30.0%	409 4.7%	86.4% 13.6%
	S	1416 16.3%	4258 49.0%	75.0% 25.0%
		64.7% 35.3%	91.2% 8.8%	79.0% 21.0%
		W	S	Skutečné

Obr. 5-3 Matice záměn testovací množiny neuronové sítě s jednou skrytou vrstvou

Predikované	W	10475 30.2%	1800 5.2%	85.3% 14.7%
	S	5527 15.9%	16930 48.7%	75.4% 24.6%
		65.5% 34.5%	90.4% 9.6%	78.9% 21.1%
		W	S	Skutečné

Obr. 5-4 Matice záměn trénovací množiny neuronové sítě s jednou skrytou vrstvou



## Sítě se dvěma skrytými vrstvami

Pro zlepšení klasifikace přichází v úvahu přidání druhé skryté vrstvy. Počet vstupních a výstupních neuronů se nezměnil (10 vstupních a 2 výstupní), počet neuronů ve skryté vrstvě byl nastaven v rozmezí mezi 15 až 25 neurony v každé ze skrytých vrstev. Pro učení byly využity algoritmy: Lavenbergův-Marquardtův algoritmus a Bayesovská regularizace, jež byly vybrány z důvodu vyšší specifity u sítí s jednou skrytou vrstvou. Počet epoch učení byl snížen na 50 kvůli vyššímu riziku přeučení (při ponechání 70 se některé sítě již přeučovaly). Výsledná sensitivity zůstává na hodnotách téměř 90 % (91 % u jedné skryté vrstvy), avšak výsledná specificita se mírně zvyšuje až na hodnotu 70 % (64 % u jedné skryté vrstvy).  $F_1$  skóre dosahuje 83 % a accuracy 80 % (u jedné skryté vrstvy bylo  $F_1$  skóre 80 % a accuracy 79 %).

Na Obr. 5-5 je vidět výsledná matice záměn sítí s 23 a 19 neurony ve skrytých vrstvách trénovaná pomocí Lavenbergova-Marquardtova algoritmu.

Predikované	W	<div>2787 32.1%</div> <div>508 5.8%</div>	<div>84.6%</div> <div>15.4%</div>
	S	<div>1196 13.8%</div> <div>4193 48.3%</div>	<div>77.8%</div> <div>22.2%</div>
		<div>70.0%</div> <div>30.0%</div> <div>89.2%</div> <div>10.8%</div> <div>80.4%</div> <div>19.6%</div>	
		W	S
		Skutečné	

Obr. 5-5 Matice záměn testovací množiny neuronové sítě se dvěma skrytými vrstvami

### 5.1.3 Klasifikace W a S neuronovou sítí pouze z dat o tepové frekvenci

Pro zjištění, zda lze klasifikovat spánek pomocí dat pouze z jednoho senzoru, byly ke klasifikaci využity pouze parametry pouze z jednoho senzoru. V tomto případě se jednalo o parametry vypočítané z tepové frekvence: kvadratický průměr a medián. Směrodatná odchylka nebyla použita z důvodu nízké frekvence snímání tepové frekvence před začátkem polysomnografie.

### Sítě s jednou skrytou vrstvou

Opět byly voleny neuronové sítě nejprve s jednou skrytou vrstvou. Vzhledem k lepším výsledkům v minulé kapitole byly jako učební algoritmy vybrány Lavenbergův-Marquardtův algoritmus a Bayesovská regularizace. Pro stanovení úspěšnosti učení byla vybrána metrika střední kvadratická odchylka (MSE).

Ve skryté vrstvě byl nastaven počet neuronů na nižší hodnoty z důvodu malého množství vstupních parametrů. Vytvořené sítě s jednou skrytou vrstvou (3 až 15 neuronů) dosahují na testovacích datech průměrné specifcity 32 % a sensitivity 78 % (při použití všech příznaků byla specifcita 64 % a sensitivita 90 %). Accuracy vycházela okolo 58 % (78 % při použití všech parametrů) a  $F_1$  skóre dosahovalo hodnoty 66 % (80 % při použití všech parametrů).

### Sítě se dvěma skrytými vrstvami

Přidáním druhé skryté vrstvy (opět s 3 až 15 neurony) zůstává výsledná specifcita okolo 31 % a sensitivita se mírně zvyšuje na hodnoty okolo 85 %. Matice záměn testovacích dat pro dvě skryté vrstvy je vidět na Obr. 5-6. Z výsledků vyplývá, že ani přidáním druhé skryté vrstvy se nezlepšují výsledky učení. Použitím pouze parametrů získaných z tepové frekvence se výrazně snižuje výsledná specifcita oproti použití všech parametrů. U sensitivity výrazný rozdíl ve výsledcích nenastal.

Predikované	W	<div>1265 14.6%</div> <div>691 8.0%</div>	<div>64.7%</div> <div>35.3%</div>
	S	<div>2784 32.1%</div> <div>3944 45.4%</div>	<div>58.6%</div> <div>41.4%</div>
		<div>31.2%</div> <div>68.8%</div>	<div>85.1%</div> <div>14.9%</div>
		W	S
		Skutečné	

Obr. 5-6 Matice záměn trénovací množiny pro data z PPG senzoru

### 5.1.4 Klasifikace W a S neuronovou sítí pouze z dat akcelerometru

Oproti minulé kapitole bylo v tomto případě pro učení neuronové sítě použito pouze parametrů vypočítaných z akcelerometrických dat. Pro vstupy bylo využito parametrů: energie, kvadratický průměr, median, směrodatná odchylka, 10% a 90% kvantil, rozpětí kvantilů a SMA. Jako učební algoritmy byly opět vybrány Lavenbergův-Marquardtův algoritmus a Bayesovská relularizace. Pro stanovení úspěšnosti učení byla zvolena MSE.

#### Sítě s jednou skrytou vrstvou

Počet neuronů ve skryté vrstvě byl nastaven v rozmezí od 15 do 25. Výsledná specifická byla dosahovala hodnot mezi  $58 \pm 2,5$  % a  $90,5 \pm 0,5$  %. Accuracy vycházela 77 % a  $F_1$  skóre bylo 80 %. (při využití všech parametrů byla  $sensitivita$  64 %,  $specifická$  91 %,  $F_1$  skóre 78 % a accuracy 79 %).

#### Sítě se dvěma skrytými vrstvami

Výsledky po přidání druhé skryté vrstvy (15 až 25 neuronů) byly velmi podobné. Specifická vyšla  $62,7 \pm 1,8$  % a  $sensitivita$   $91 \pm 0,6$  %. Pro všechny sítě vyšlo  $F_1$  skóre v rozmezí 75 % až 79 %. Celková úspěšnost byla okolo 76 % (při využití všech parametrů byla  $sensitivita$  70 %,  $specifická$  90 %,  $F_1$  skóre 80 % a accuracy 80 %). Matice záměn na testovací množině je vidět na Obr. 5-7.

Predikované	W	<div>2925</div> <div>31.1%</div>	<div>428</div> <div>4.5%</div>	<div>87.2%</div> <div>12.8%</div>
	S	<div>1736</div> <div>18.4%</div>	<div>4326</div> <div>45.9%</div>	<div>71.4%</div> <div>28.6%</div>
		<div>62.8%</div> <div>37.2%</div>	<div>91.0%</div> <div>9.0%</div>	<div>77.0%</div> <div>23.0%</div>
		W	S	Skutečné

Obr. 5-7 Matice záměn testovací množiny pro data z akcelerometru

### 5.1.5 Porovnání dosažených výsledků při klasifikaci W a S

Tabulka 5-2 zobrazuje porovnání úspěšnosti klasifikace W/S pomocí rozdílných přístupů. Je vidět, že síť se dvěma skrytými vrstvami dosahuje lepší specifity než síť s jednou skrytou vrstvou. Při použití pouze části parametrů je dosaženo horších výsledků než při použití všech parametrů.

**Tabulka 5-2 Porovnání výsledků dosažených při klasifikaci W a S**

Použité parametry	Počet skrytých vrstev	Specifita [%]	Sensitivita [%]	F1 skóre [%]	Accuracy [%]
Pouze z tepové frekvence	1	32	78	66	58
	2	31	85	69	60
Pouze z akcelerometru	1	58	90	80	77
	2	63	91	78	76
Akcelerometr a tepová frekvence	1	65	90	80	79
	2	70	89	83	79

## 5.2 Klasifikace W, NREM a REM pomocí neuronových sítí

Pro rozdělení dat do tří skupin bylo využito pouze metod klasifikace pomocí neuronových sítí. Tato metoda byla zvolena kvůli jednoduchosti rozdělení dat do více skupin. Data byla opět náhodně rozdělena v poměru 80 % pro učení a 20 % pro testování sítě. Nejprve byly trénovány neuronové sítě s jednou skrytou vrstvou. Jako v případě první klasifikace do skupin W a S bylo využito pěti učebních algoritmů, a to: Lavenbergova-Marquardtova algoritmu, gradientního poklesu, gradientního poklesu s adaptivními vahami, algoritmu Scaled conjugate gradient a Bayesovské regularizace. V případě jedné skryté vrstvy byl počet neuronů nastaven na 10 až 30, u dvou skrytých vrstev byly počty neuronů v rozmezí 15 až 25. Pro stanovení úspěšnosti učení byla zvolena MSE.

V případě nebinární klasifikace byly pro statistické zhodnocení výsledků vypočítány parametry: sensitivita (procento správného určení dané kategorie), pozitivní prediktivní hodnota každé kategorie a celkovou přesnost (accuracy). Ukázka matice záměn pro 3 kategorie je vidět v: Tabulka 5-3.


**Tabulka 5-3 Příklad matice záměn pro tři kategorie**

		Skutečná kategorie			
		W	NREM	REM	
Predikovaná kategorie	W	Správná predikce W	Chybně predikováno jako W	Chybně predikováno jako W	PPV W
	NREM	Chybně predikováno jako NREM	Správná predikce NREM	Chybně predikováno jako NREM	PPV NREM
	REM	Chybně predikováno jako REM	Chybně predikováno jako REM	Správná predikce REM	PPV REM
		TPR W	TPR NREM	TPR REM	Accuracy

### Sít' s jednou skrytou vrstvou

Pro porovnání výsledků učení sítí je na Obr. 5-8 zobrazen graf průměrů sensitivity (true positive rate – správné určení kategorie W, NREM, REM) pro jednotlivé učební algoritmy. Tyto modely mají lehce nižší úspěšnost klasifikace fáze W jako modely rozlišující pouze W/S (63 % oproti 65 %). Avšak rozlišení fází REM a NREM není dobré. Sensitivita NREM je u modelů nižší než 50 %. Sensitivita REM spánku je u algoritmů Bayesovské regularizace, Scaled conjugate gradient a Lavenbergova-Marquardtova algoritmu v rozmezí 55 % až 65 %. U modelů s učební funkcí gradientního poklesu je o okolo 30 %. Celková úspěšnost (accuracy) je okolo 58 %. V případě těchto sítí tak dochází k velmi časté záměně fází NREM a REM spánku.

Matice záměn sítě naučené Lavenbergovým-Marquardtovým algoritmem s jednou skrytou vrstvou je zobrazena na Obr. 5-9. Jedná se o výsledky sítě s 22 neurony ve skryté vrstvě.



**Obr. 5-8 Průměr sensitivity (TPR) různých učebních algoritmů pro jednotlivé kategorie**

Predikované	W	2553 22.8%	315 2.8%	439 3.9%	77.2% 22.8%
	NREM	567 5.1%	1600 14.3%	891 8.0%	52.3% 47.7%
	REM	937 8.4%	1588 14.2%	2305 20.6%	47.7% 52.3%
		62.9% 37.1%	45.7% 54.3%	63.4% 36.6%	57.7% 42.3%
		Skutečné			
		W	NREM	REM	

**Obr. 5-9 Matice záměn neuronové sítě s jednou skrytou vrstvou pro rozlišení W/NREM/REM**

### Sít' se dvěma skrytými vrstvami

Následným krokem bylo přidání druhé skryté vrstvy. Vzhledem k výsledkům sítí v grafu na Obr. 5-8 bylo pro učení použito Bayesovské regularizace, algoritmu Scaled conjugate gradient a Lavenbergova-Marquardtova algoritmu. Počet neuronů byl nastaven v rozmezí od 15 do 25 neuronů v každé skryté vrstvě. Výsledné hodnoty jsou u všech algoritmů velmi podobné. Specificita fáze W je v rozmezí 63 % až 65 %, je vyšší než u sítí s jednou skrytou vrstvou (62 %), ale nižší než u sítí rozlišující pouze kategorie W a S (70 %). U specifity fáze NREM došlo k zvýšení na průměrnou hodnotu 50,5 % a specificita fáze REM zůstala na téměř stejných hodnotách (63 %).

Matice záměn trénovaná pomocí algoritmu Bayesovské regularizace s 22 a 18 neurony ve skrytých vrstvách je zobrazena na Obr. 5-10.

Predikované	W	NREM	REM	
	2596 23.2%	313 2.8%	402 3.6%	78.4% 21.6%
	603 5.4%	1762 15.7%	950 8.5%	53.2% 46.8%
	861 7.7%	1438 12.8%	2270 20.3%	49.7% 50.3%
				63.9% 36.1%
				50.2% 49.8%
				62.7% 37.3%
				59.2% 40.8%
				W
				NREM
				REM
				Skutečné

Obr. 5-10 Matice záměn neuronové sítě s dvěma skrytými vrstvami pro rozlišení W/NREM/REM

### 5.3 Porovnání dosažených výsledků s literaturou

Ke srovnání dosažených výsledků klasifikace je v následující tabulce (viz Tabulka 5-4) zobrazeno porovnání s jinými autory.

**Tabulka 5-4 Porovnání výsledků klasifikace s literaturou**

<b>Autor, rok publikace</b>	<b>Zdroj dat</b>	<b>Klasifikované skupiny</b>	<b>Metoda</b>	<b>Sensitivita (TPR) [%]</b>	<b>Specifita [%]</b>
<b>Navržená metoda</b>	<b>Akcelerometr (zápěstí) PPG senzor</b>	<b>W/S W/NREM/ REM</b>	<b>Neuronové sítě</b>	<b>89 W: 64 REM: 50 NREM: 63</b>	<b>70</b>
Walsch, O. [6], 2019	Akcelerometr (zápěstí) PPG senzor	W/S, W/NREM/RE M	Neuronové sítě	93 W: 60 REM: 62 NREM: 62	62
Girardin, JL. [26], 2001	Akcelerometr (zápěstí)	W/S	Adaptivní prahování	85	54
Nelleke, C. [27]	Akcelerometr (zápěstí) Záznam EKG Senzor teploty těla (IČ), Senzor teploty kůže	W/S	Neuronové sítě	83	73
Aktaruzzaman, Md [28]	Akcelerometr (zápěstí) Akcelerometr (prsa) Záznam EKG	W/S	Support Vector Machines	90	78

Dále se nabízí srovnání s komerčními produkty. Kromě velkého množství chytrých náramků a hodinek je na trhu například prsten Oura. Tento prsten, který se řadí do kategorie nositelné elektroniky, se přímo zaměřuje na hodnocení kvality spánku. Při klasifikaci spánku do tří skupin (W, NREM a REM) dosahuje Oura sensitivity (TPR) fáze NREM 83 % a sensitivity (TPR) fáze REM 64 %. U celkového času spánku (TST) získaného na základě snímání prstenem není statisticky významný rozdíl od TST změřeného pomocí zlatého standardu v podobě PSG vyšetření. [29]



## 6. VÝPOČET PARAMETRŮ HODNOTÍCÍCH KVALITU SPÁNKU

Naučená neuronová síť byla využita ke skórování spánku u všech osob, u nichž se podařilo nasnímat celonoční záznam. Výstupy klasifikátoru byly následně použity pro odvození parametrů běžně používaných pro kvantitativní hodnocení kvality spánku (viz kapitola 2.4). Hodnocení kvality spánku proběhlo jak s využitím výstupu binární klasifikace (spánek/bdění), tak i výstupu klasifikace do tří kategorií (NREM spánek/REM spánek/bdění).

### Hodnocení kvality spánku na základě výstupu binárního klasifikátoru


Vzhledem k binární klasifikaci dat, tj. rozdělení jednotlivých epoch do dvou kategorií (W a S) bylo možné vypočítat následující parametry:

- celkový čas záznamu (TRT)
- celkový čas spánku (TST)
- efektivita spánku (SE)
- celkový čas strávený vzhůru (TWT)
- zpoždění počátku spánku (Sleep latency)
- probuzení po počátku spánku (WASO)

I přes slibné výsledky při trénování sítí je u části pacientů chybně vyhodnocena část spánku (S) jako bdělost (W). Tento fakt je pravděpodobně způsoben přípravou dat pro trénování sítí. Síť byla trénovaná na datech získaných během současného PSG vyšetření a na datech naměřených před tímto vyšetřením. Avšak dat před PSG vyšetřením bylo méně. Pro trénování neuronové sítě je vhodné mít stejně vzorků, proto byla data nakopírována, což ovlivnilo výsledky u testování sítí, které byly pravděpodobně nadhodnocené. Dále tom může být způsobeno i limitací samotné metody, jak již bylo zmíněno, na základě využívaných dat nelze přesně rozlišit, zda je osoba v klidu a relaxuje, anebo jestli je v klidu a spí.

Vzhledem k výsledkům v kap. 5.1.2 byla pro klasifikaci vybrána síť s 23 a 19 neurony ve skrytých vrstvách, která byla trénována pomocí Lavenbergova-Marquardtova algoritmu. Síť byla vždy natrénovaná na všech vzorcích kromě jednoho, který byl testován.


Na Obr. 6-1 je zobrazen graf, kde je vidět celkový čas spánku vypočítaný jak na základě hodnocení PSG dat expertem, tak odhadnutý na základě výstupu z neuronové sítě.



**Obr. 6-1 Porovnání parametru TST získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, S)**

Na předchozím grafu jsou vidět rozdíly v parametru TST, tento parametr je důležitý, protože na něm závisí výpočet dalších parametrů (např. SE). Je vidět, že u některých pacientů je TST vypočítaný na základě hodnocení experta vyšší než TST odhadnutý na základě výstupu neuronové sítě. U pacientů č. 17 a 19 je tento rozdíl až 100 minut. Naopak u některých pacientů je TST vyšší u odhadu pomocí neuronové sítě (u pacientů 5 a 6 je to o 75 resp. 65 minut). Tyto rozdíly mohou být způsobeny přechodem mezi fázemi, či samotnou fází REM spánku. Tento problém je více diskutován níže, na přiloženém hypnogramu (Obr. 6-4).

Na následujícím Obr. 6-2 je vykreslena závislost TST odhadnutého pomocí klasifikace neuronovou sítí a TST vypočteného na základě hodnocení experta. Čím blíže jsou body ke zobrazené uhlopříčce, tím přesnější bylo hodnocení.



**Obr. 6-2 Závislost TST odhadnutého pomocí klasifikace neuronovou sítí (W, S) na TST vypočteného na základě hodnocení experta**

Dalším důležitým parametrem je zpoždění počátku spánku (sleep latency). Tento parametr říká, jak rychle je pacient schopný usnout. Zde byly velké rozdíly mezi výsledky získanými hodnocením experta a výsledky odhadnutými na základě výstupu neuronové sítě. Na Obr. 6-3 je tento rozdíl zobrazen. U pacientů č. 1, 10, 11, 17, 23 a 24 byla neuronovou sítí zaznamenána první epocha spánku již krátce po začátku měření, avšak pacient byl vzhůru ještě několik dalších minut. Naopak u pacientů č. 4, 14, 16 a 19 byla neuronovou sítí klasifikována první epocha spánku až několik minut po usnutí. Tyto rozdíly jsou pravděpodobně způsobeny jedinečností každého pacienta, kdy síť není schopná rozlišit, zda jedinec již opravdu spí, nebo se snaží nehybně a v klidu usnout.




**Obr. 6-3 Porovnání zpoždění počátku spánku vypočítaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, S)**

Na následujícím Obr. 6-4 je vykreslena část hypnogramu získaného hodnocením výsledků PSG vyšetření expertem a stejný úsek odhadnutý na základě výstupu neuronové sítě. Na ose y jsou zobrazeny jednotlivé fáze spánku. Pro hypnogram získaný z neuronové sítě znamená 0 fázi W a 2 fázi S. U hypnogramu získaného hodnocením experta znamená 0 fázi W, 1 fázi N1, 2 fázi N2, 3 fázi N3 a 5 fázi REM. Na počátku zobrazené časové osy (čas 3,5 h) je pacient vzhůru. Neuronová síť zde při hodnocení velmi často mění svůj výstup mezi W a S. Po usnutí daného pacienta (ve fázi N2 spánku) síť velmi dobře rozlišuje epochy S. Také je zde vidět reakce sítě na krátké probuzení v čase těsně před 4. hodinou. Síť má následně problém s hodnocením ve chvíli, kdy je pacient ve fázi REM spánku. Během této doby je výstup sítě stále měněn mezi W a S. Po


skončení REM fáze následuje část N1 spánku, kterou síť považuje za probuzení (W). Po návratu pacienta do N2 fáze spánku již neuronová síť správně hodnotí další epochy jako spánek.

Těmito přechody mezi fázemi NREM a REM spánku vzniká největší množství epoch spánku (S), které jsou klasifikovány jako bdělost (W).

Na obr. Obr. 6-5 je poté ještě vidět SE odhadnutá pomocí klasifikace neuronovou sítí a SE vypočtená na základě hodnocení experta.



**Obr. 6-4 Porovnání hypnogramů sestavených na základě hodnocení PSG vyšetření expertem a na základě výstupu z neuronové sítě (W, S)**




**Obr. 6-5 Závislost SE odhadnuté pomocí klasifikace neuronovou sítí (W, S) na SE vypočtené na základě hodnocení experta**

## Hodnocení kvality spánku na základě výstupu vícekategoriálního (W, NREM a REM) klasifikátoru

V případě rozdělení dat do tří kategorií (W, NREM a REM) lze vypočítat stejné parametry hodnotící kvalitu spánku jako při binárním rozdělení (TRT, TST, SE, TWT, WASO, sleep latency). Navíc lze ještě vypočítat zpoždění začátku fáze REM (Stage R latency) a procentuální zastoupení REM fáze v celkové době spánku.

Klasifikace do jednotlivých skupin proběhla pomocí zvolené neuronové sítě. Jednalo se o síť se dvěma skrytými vrstvami (s 22 a 18 neurony). Síť byla trénována pomocí Lavenbergova-Marquardtova algoritmu. Výběr této sítě byl diskutován v kap. 5.2. Na Obr. 6-6 je zobrazen parametr TST, který je vypočítán jak na základě hodnocení PSG dat expertem, tak odhadnutý na základě výstupu z neuronové sítě.




**Obr. 6-6 Porovnání parametru TST získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, NREM, REM)**

Z grafů na Obr. 6-1 a Obr. 6-6 je patrné, že celková doba spánku odhadnutá pomocí neuronové sítě je velmi podobná, ať se jedná o síť, která klasifikovala data binárně (W, S), nebo o síť, která klasifikovala data do 3 skupin (W, NREM, REM). Při součtu absolutních hodnot rozdílů mezi TST vypočítanými na základě hodnocení dat expertem a TST odhadnutých na základě výsledků neuronové sítě je průměrný rozdíl  $TST_{WS}$  (při klasifikaci W, S) 31,2 minut a průměrný rozdíl  $TST_{WNR}$  (při klasifikaci do skupin W, NREM a REM) 36,3 minut. Jedná se o rozdíly (v abs. hodnotě) mezi TST vypočítanými na základě hodnocení experta a TST odhadnutými na základě výstupu neuronové sítě.

Problémem při této klasifikaci do tří skupin je záměna NREM a REM fází spánku. V některých případech (u 7 testovaných osob) byly zaměněny téměř všechny epochy NREM


spánku za REM spánek. Na Obr. 6-7 je vykresleno porovnání % R (REM) spánku u dat hodnocených expertem a dat získaných na základě výstupu neuronové sítě.



**Obr. 6-7 Porovnání parametru % REM spánku získaného na základě hodnocení dat expertem a na základě výstupu neuronové sítě (W, NREM, REM)**

Tato záměna NREM a REM spánku je pravděpodobně způsobená nedostatečnou diagnostickou výtěžností dat z náramku, kvůli níž nebyla neuronová síť schopná správně zařadit data během spánku do skupin NREM a REM.

Parametr zpoždění fáze R (R stage latency) je také velmi zatížen touto chybou. U některých osob je fáze R jako první klasifikovanou fází spánku (viz graf na Obr. 6-8). Výsledky ostatních parametrů jsou velmi podobné jako při binární klasifikaci dat.



**Obr. 6-8 Závislost R latency odhadnuté pomocí klasifikace neuronovou sítí (W, NREM, REM) na SE vypočtené na základě hodnocení experta**

# ZÁVĚR

Prvním cílem této práce bylo se za pomoci literární rešerše seznámit s metodami počítačového zpracování a analýzy biologických signálů naměřených ve spánku s důrazem na metody používané pro detekci spánku a metriky pro hodnocení kvality spánku. Tato problematika je rozebrána v úvodních dvou kapitolách práce. První kapitola obsahuje popis fyziologie spánku pro snadnější pochopení analyzované problematiky. Jedná se především o biologický rytmus, fáze spánku, spánkový cyklus a vybrané poruchy ovlivňující kvalitu spánku. Druhá kapitola se věnuje již zmiňovaným metodám monitorování spánku. Mezi hlavní metody využívané v klinické praxi můžeme zmínit dotazníky, spánkové deníky, dlouhodobá aktigrafická měření a polysomnografická vyšetření.

Dalšími cíli práce bylo seznámení se s databází spánkových signálů, navržení postupu pro odhad kvality spánku a následná realizace této metody v prostředí MATLAB. Dále pak statistické vyhodnocení účinnosti navržené metody a interpretace dosažených výsledků.

Jako databáze spánkových signálů byl zvolen soubor signálů naměřený během studie *Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device* [6]. Tato databáze byla zvolena z důvodu volného přístupu k aktigrafickým signálům od více jak 30 osob a zároveň databáze obsahovala i celonoční záznam spánku ohodnocený spánkovým expertem. Takto získaná data byla pomocí zvolených postupů předzpracována a následně z nich byly vypočteny parametry sloužící jako vstupy do neuronových sítí.

Pro samotný výpočet parametrů kvality spánku byla data nejprve rozdělena do jednotlivých kategorií, nejprve na bdělost a spánek (skupiny W a S) a následně také na bdělost, NON REM a REM spánek. Toto rozdělení bylo zajištěno pomocí neuronových sítí. Jednalo se o dopředné neuronové sítě, u kterých byl vždy nastaven učební algoritmus, počty neuronů ve skrytých vrstvách a funkce měření výkonosti (performance function). Tyto sítě dosahovaly sensitivity téměř 90 % a specificity až 70 %. Pomocí sítí s nejvyšší specificitou a sensitivitou byla data rozdělena na epochy bdělosti a spánku (popřípadě na bdělost, NON REM a REM spánek) a byly vypočítány parametry hodnotící kvalitu spánku.

U parametrů hodnotících kvalitu spánku odhadnutých na základě výstupu z neuronové sítě vznikl rozdíl oproti parametrům vypočteným na základě hodnocení experta. Rozdíly byly zjištěny především u parametrů souvisejících s určováním fáze REM. U parametru, který ukazuje procentuální zastoupení REM spánku (% REM) odhadnutého na základě neuronové sítě byl průměrný rozdíl 76 % ve srovnání s hodnocením PSG dat expertem. Při porovnávání parametrů souvisejících s REM fází narážíme na hranice těchto metod, kdy z dostupných dat není možnost

rozlišit REM a NREM spánek s dostatečnou kvalitou. Naproti tomu u celkové doby spánku (TST) byl průměrný rozdíl pouze 7,1 % (31 minut). Tento rozdíl leží na hranici 30 minut, do které je klinické hodnocení spánkových dat tímto parametrem (TST) považováno za smysluplné [29]. Výše popisované metody hodnocení kvality spánku na základě výstupu z neuronové sítě je tudíž možné použít pro sledování celkové doby spánku, za účelem např. dlouhodobého monitoringu. Pro využití ke složitějším rozborům spánku, například ke zjištění rozložení fází REM v průběhu celého spánku však tato metoda není vhodná.

Pro zpřesnění výsledků by mohlo pomoci zvětšení trénovací množiny dat pomocí nových měření. Další možností je případné přidáním snímače okolního osvětlení, který by pomáhal rozlišením například četby vleže a spánku. Vzhledem ke kolísání tělesné teploty v průběhu dne by její měření také dopomohlo k přesnější klasifikaci. K diskuzi by také byla změna umístění senzorů. Umístění akcelerometru například k pasu, kdy budou známy polohy jednotlivých os vůči tělu jistě zlepši výsledky, avšak bude mít negativní vliv na komfort nošení. Využití těchto postupů by mohlo být předmětem dalšího zkoumání.



## Literatura

- [1] *Circadian Rhythms* [online]. Bethesda (Maryland), 2017 [cit. 2019-12-08]. Dostupné z: [https://www.nigms.nih.gov/education/pages/factsheet\\_circadianrhythms.aspx](https://www.nigms.nih.gov/education/pages/factsheet_circadianrhythms.aspx)
- [2] Deng, Z., Arsenault, S., Caranica, C. *et al.* Synchronizing stochastic circadian oscillators in single cells of *Neurospora crassa*. *Sci Rep* **6**, 35828 (2016)
- [3] WELSH, David, Seung-Hee YOO, Andrew LIU, Joseph TAKAHASHI a Steve KAY. Bioluminescence Imaging of Individual Fibroblasts Reveals Persistent, Independently
- [4] SPRIGGS, William H. *Essentials of polysomnography: a training guide and reference for sleep technicians*. Sudbury, Mass.: Jones and Bartlett, c2010. ISBN 978-0-7637-8106-4.
- [5] NEVŠÍMALOVÁ, Soňa a Karel ŠONKA. *Poruchy spánku a bdění*. 2., dopl. a přeprac. vyd. Praha: Galén, c2007. ISBN isbn978-80-7262-500-0.
- [6] OLIVIA, Walch, Huang YITONG, Forger DANIEL a Goldstein CATHY. Sleep stage prediction with raw acceleration and photoplethysmography heart rate data derived from a consumer wearable device. *SLEEP*. 2019, **42**(8).
- [7] *Spánkový deník FN BRNO* [online]. [cit. 2019-12-06]. Dostupné z: <https://www.fnbrno.cz/spankovy-denik/f4717>
- [8] MIGUEL, Marino, Li YI, Rueschman MICHAEL a et al. Measuring Sleep: Accuracy, Sensitivity, and Specificity of Wrist Actigraphy Compared to Polysomnography. *SLEEP*. 2013, **36**(11), 1747-1755.
- [9] ANCOLI-ISR0AEL, Sonia, Cole ROGER, Alessi CATHY a et al. The role of actigraphy in the study of sleep and circadian rhythms. *SLEEP*. 2003, **26**(3), 342-92.
- [10] Non-24-Hour Sleep-Wake Circadian Rhythm Disorder in a Sighted Male With Normal Functioning - Scientific Figure on ResearchGate [online]. [cit 2019-12-27]. Dostupné z: [https://www.researchgate.net/figure/Actigraphy-data-showing-progressive-daily-delays-in-sleep-and-wake-times\\_fig2\\_323318152](https://www.researchgate.net/figure/Actigraphy-data-showing-progressive-daily-delays-in-sleep-and-wake-times_fig2_323318152)
- [11] Berry RB, Brooks R, Gamaldo CE, Harding SM, Lloyd RM, Marcus CL and Vaughn BV for the American Academy of Sleep Medicine. The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specifications, Version 2.2. [www.aasmnet.org](http://www.aasmnet.org). Darien, Illinois: American Academy of Sleep Medicine, 2015.
- [12] NASCAR, Eduard. *Screenshot of a person in stage N3 sleep* [online]. In: . [cit. 2020-05-24]. Dostupné z: [https://commons.wikimedia.org/wiki/File:Sleep\\_Stage\\_N3.png](https://commons.wikimedia.org/wiki/File:Sleep_Stage_N3.png)
- [13] WENDT, Sabrina L., Peter WELINDER a Helge B.D. SORENSEN. Inter-expert and intra-expert reliability in sleep spindle scoring. *Clinical Neurophysiology*. 2015, **66**(8), 1548-1556.
- [14] HANRAHAN, Grady. *Artificial neural networks in biological and environmental analysis*. Boca Raton: CRC Taylor & Francis, c2011. Analytical chemistry. ISBN 978-1-4398-1258-7
- [15] KOZUMPLÍK, Jiří a Ivo PROVAZNÍK. *Umělá inteligence v medicíně* [online]. VUT Brno, 2007 [cit. 2020-03-20].
- [16] *Metoda Podpůrných vektroů* [online], MUNI Brno, 2006 [cit. 2020-05-25]. Dostupné z: [https://is.muni.cz/el/1433/podzim2006/PA034/09\\_SVM.pdf](https://is.muni.cz/el/1433/podzim2006/PA034/09_SVM.pdf)
- [17] *Support Vector Machines* [online], poslední aktualizace 28.3 2019 22:46 [cit. 4. 6. 2020], Wikipedie. Dostupné z [https://cs.wikipedia.org/wiki/Support\\_vector\\_machines](https://cs.wikipedia.org/wiki/Support_vector_machines)

- [18] Phased Circadian Rhythms of Clock Gene Expression. *Current Biology*. 2004, **14**(24), 2289-2295.
- [19] STMicroelectronics [online katalogový list]. *LSM6DS3*. 2017 [cit. 2019-12-10]. Dostupné z:  
<https://www.st.com/content/ccc/resource/technical/document/datasheet/a3/f5/4f/ae/8e/44/41/d7/DM00133076.pdf/files/DM00133076.pdf/jcr:content/translations/en.DM00133076.pdf>
- [20] Lai, Ying-Chih & Chang, Chin-Chia & Tsai, Chia-Ming & Huang, Shih-Ching & Chiang, Kai-Wei. (2016). A Knowledge-Based Step Length Estimation Method Based on Fuzzy Logic and Multi-Sensor Fusion Algorithms for a Pedestrian Dead Reckoning System. *ISPRS International Journal of Geo-Information*.
- [21] FARKAS, Ioana a Elena DORAN. Activity recognition from acceleration data collected with a tri-axial accelerometer. *PRODOC* [online]. 2011, **52**(2), 38-43 [cit. 2020-05-25]. Dostupné z:  
<https://pdfs.semanticscholar.org/c4d7/1ccd99d5c0b313111ca92f3399e903db35c7.pdf>
- [22] Nham,B.;Siangliulue,K.;Yeung,S.PredictingModeofTransportfromiPhoneAccelerometer Data; CS 229; Machine Learning Final Projects, Stanford University: Stanford, CA, USA, 2008.
- [23] BERSCH, Sebastian, Rinat KHUSAINOV a Ifeyinwa ACHUMBA. Sensor Data Acquisition and Processing Parameters for Human Activity Classification. *Sensors*. 2014, **14**
- [24] BUDÍKOVÁ, Marie, Maria KRÁLOVÁ a Bohumil MAROŠ. *Průvodce základními statistickými metodami*. Praha: Grada, 2010. Expert (Grada). ISBN 978-80-247-3243-5.
- [25] van Hees, Vincent & Sabia, S. & Jones, Samuel & Wood, A. & Anderson, Kirstie & Kivimäki, M. & Frayling, T. & Pack, A. & Bucan, M. & Trenell, M. & Mazzotti, Diego & Gehrman, Philip & Singh-Manoux, Archana & Weedon, Michael. (2018). Estimating sleep parameters using an accelerometer without sleep diary. *Scientific Reports*.
- [26] GIRARDIN, Jean-Luis. Sleep detection with an accelerometer actigraph: comparisons with polysomnography. *Physiology & Behavior*. 2001, **72**(1), 21-28.
- [27] NELLEKE, C. Sleep Monitoring: A Comparison Between Three Wearable Instruments. *Military Medicine*. 2011, **76**(7), 811-816.
- [28] AKTARUZZAMAN, Md. Performance comparison between wrist and chest actigraphy in combination with heart rate variability for sleep classification. *Computers in Biology and Medicine*. 2017, (1), 212-221.
- [29] KINNUNEN, Hannu. Sleep Lab validation of a wellness ring in detecting sleep patterns based on photoplethysmogram, actigraphy and body temperature [online]. 2016 [cit. 2020-06-05]. Dostupné z: <https://d1a0efioav7lro.cloudfront.net/wp-content/uploads/2018/10/23112923/Validity-of-the-OURA-Ring-in-determining-Sleep-Quantity-and-Quality-2016.pdf>